



UNIVERSITAS INDONESIA

**PEMANFAATAN DOKUMEN *UNLABELED* PADA
KLASIFIKASI TOPIK BERBASIS NAÏVE BAYES DENGAN
ALGORITMA EXPECTATION MAXIMIZATION**

SKRIPSI

Bayu Distiawan Trisedya

1205000215

PROGRAM: ILMU KOMPUTER

FAKULTAS: ILMU KOMPUTER

DEPOK

JULI, 2009



UNIVERSITAS INDONESIA

**PEMANFAATAN DOKUMEN *UNLABELED* PADA
KLASIFIKASI TOPIK BERBASIS NAÏVE BAYES DENGAN
ALGORITMA EXPECTATION MAXIMIZATION**

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar S.Kom

Bayu Distiawan Trisedya

1205000215

PROGRAM: ILMU KOMPUTER

FAKULTAS: ILMU KOMPUTER

DEPOK

JULI, 2009

HALAMAN PERNYATAAN ORISINALITAS

**Skripsi ini adalah hasil karya saya sendiri,
dan semua sumber baik yang dikutip maupun dirujuk
telah saya nyatakan dengan benar.**

Nama : Bayu Distiawan Trisedya
NPM : 1205000215

Tanda Tangan :
Tanggal : 27 Juli 2009

HALAMAN PENGESAHAN

Skripsi ini diajukan oleh :

Nama : Bayu Distiawan Trisedya

NPM : 1205000215

Program Studi : Ilmu Komputer

Judul Skripsi : Pemanfaatan Dokumen *Unlabeled* pada Klasifikasi Topik Berbasis
Naïve Bayes dengan Algoritma Expectation Maximization

**Telah berhasil dipertahankan di hadapan Dewan Pengaji dan diterima sebagai
bagian persyaratan yang diperlukan untuk memperoleh gelar Sarjana S.Kom
pada Program Studi Ilmu Komputer, Fakultas Ilmu Komputer, Universitas
Indonesia**

DEWAN PENGUJI

Pembimbing : Dr. Hisar Maruli Manurung, S.Kom (.....)

Pengaji : Dra. Mirna Adriani, Ph.D (.....)

Pengaji : Dr. Achmad Nizar Hidayanto (.....)

Ditetapkan di : Fakultas Ilmu Komputer

Tanggal : 27 Juli 2009

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Tuhan Yang Maha Esa karena atas karunia dan rahmat-Nya akhirnya penulis dapat menyelesaikan tugas akhir dalam jangka waktu yang telah ditentukan dan menghasilkan laporan tugas akhir ini. Selama melakukan tugas akhir, penulis mendapatkan bantuan dari berbagai pihak yang sangat berarti bagi penulis. Oleh sebab itu, penulis hendak menyampaikan ungkapan terima kasih kepada berbagai pihak sebagai berikut:

1. Orang tua, kakak, dan seluruh anggota keluarga lainnya yang selalu memberi dukungan, semangat, dan motivasi kepada penulis dalam menyelesaikan tugas akhir ini;
2. Bapak Ruli Manurung selaku dosen pembimbing tugas akhir;
3. Ibu Dina Cahyati selaku dosen pembimbing akademis;
4. Mr. Kamal Nigam yang telah bersedia menjawab pertanyaan-pertanyaan seputar klasifikasi dokumen serta memperkenalkan MinorThird sebagai *tools* dalam melakukan eksperimen klasifikasi dokumen;
5. Armando, Bernadia, Clara, Darwin, Denny, Hansel, Heninggar, Metti, Mulyandra, Refly, Rizal, Suryanto, Teddy, Vinky, dan rekan-rekan yang ada di Lab IR selama penggerjaan tugas akhir. Terima kasih karena telah membantu, mendukung, dan menemani penulis selama penggerjaan tugas akhir;
6. Achmad Rohman dan Mursal Rais yang telah memberi kritik dan saran selama penulisan laporan tugas akhir;
7. Adit, Bambang, Haryadi, Prajna, Rizky, Rio, dan rekan-rekan ekstrakulikuler badminton 2005 serta rekan-rekan tim futsal KTTK yang telah membantu, mendukung, dan menemani penulis selama penggerjaan tugas akhir;

8. Teman-teman Fakultas Ilmu Komputer Universitas Indonesia angkatan 2005 yang namanya tidak dapat disebutkan satu per satu di sini;
9. Semua staf pengajar, administrasi, dan keluarga besar Fakultas Ilmu Komputer Universitas Indonesia;
10. Semua pihak yang belum tersebutkan di atas, yang secara langsung maupun tidak langsung telah memberikan kontribusi dan bantuannya atas kelancaran dan kesuksesan tugas akhir hingga penyusunan laporan ini.

Penulis sangat sadar bahwa dalam melakukan penelitian ini banyak kekurangan dan kesalahan yang telah penulis lakukan. Oleh karena itu, penulis sangat terbuka untuk setiap kritik dan saran yang membangun. Akhir kata, penulis berharap semoga laporan tugas akhir ini dapat memberi manfaat kepada para pembaca.

Depok, 27 Juli 2009

Bayu Distiawan Trisedya

HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademik Universitas Indonesia, saya yang bertanda tangan di bawah ini:

Nama : Bayu Distiawan Trisedya
NPM : 1205000215
Program Studi : Ilmu Komputer
Fakultas : Ilmu Komputer
Jenis karya : Skripsi

demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Indonesia **Hak Bebas Royalti Noneksklusif (Non-exclusive Royalty-Free Right)** atas karya ilmiah saya yang berjudul :

Pemanfaatan Dokumen *Unlabeled* pada Klasifikasi Topik Berbasis Naïve Bayes dengan Algoritma Expectation Maximization

beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Indonesia berhak menyimpan, mengalihmedia/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Depok
Pada tanggal : 27 Juli 2009
Yang menyatakan

(Bayu Distiawan Trisedya)

DAFTAR ISI

HALAMAN JUDUL.....	i
HALAMAN PERNYATAAN ORISINALITAS.....	ii
HALAMAN PENGESAHAN.....	iii
KATA PENGANTAR	iv
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS	vi
ABSTRAK.....	vii
ABSTRACT.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xii
DAFTAR GAMBAR	xiii
DAFTAR PERSAMAAN	xv
DAFTAR LAMPIRAN	xvi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Permasalahan.....	2
1.3 Tujuan.....	2
1.4 Ruang Lingkup	2
1.5 Metodologi Penelitian	3
1.6 Sistematika Penulisan.....	3
BAB 2 LANDASAN TEORI.....	6
2.1 Klasifikasi Dokumen Teks	6
2.2 <i>Machine Learning</i> untuk Klasifikasi Dokumen Teks	7
2.3 Naïve Bayes.....	9
2.4 Expectation Maximization	11

2.5	Klasifikasi Dokumen Bahasa Indonesia	15
BAB 3	PERANCANGAN	17
3.1	Gambaran Umum Proses Klasifikasi Dokumen Teks	17
3.2	Data	19
3.3	Persiapan Dokumen.....	21
3.3.1	<i>Converting</i>	21
3.3.2	<i>Filtering</i>	21
3.4	<i>K-fold Cross Validation</i>	22
3.5	Pemilihan Fitur	22
3.6	<i>Term Documents Matrix</i>	24
3.7	Metode Klasifikasi Dokumen Teks	26
3.7.1	Naïve Bayes	26
3.7.2	Expectation Maximization	29
BAB 4	IMPLEMENTASI.....	38
4.1	Persiapan Dokumen.....	38
4.1.1	<i>Converting</i>	38
4.1.2	<i>Filtering</i>	40
4.2	Pemilihan Fitur	42
4.3	<i>K-fold Cross Validation</i>	43
4.4	Pembuatan <i>Term Documents Matrix</i>	44
4.5	Klasifikasi Dokumen Teks	46
4.5.1	Naïve Bayes	47
4.5.2	Expectation Maximization	50
BAB 5	HASIL DAN PEMBAHASAN	53
5.1	Variabel Eksperimen	53
5.2	Hasil Eksperimen terhadap Jumlah Fitur dan Penghilangan <i>Stopwords</i>	55

5.2.1	Hasil Klasifikasi untuk Data Dokumen Hukum.....	56
5.2.2	Hasil Klasifikasi untuk Data Artikel Media Massa.....	59
5.2.3	Hasil Klasifikasi untuk Data 20Newsgroups <i>Dataset</i>	61
5.3	Hasil Klasifikasi dari Aspek Jenis Fitur	63
5.3.1	Hasil Klasifikasi untuk Data Dokumen Hukum.....	63
5.3.2	Hasil Klasifikasi untuk Data Artikel Media Massa.....	64
5.3.3	Hasil Klasifikasi untuk Data 20Newsgroups <i>Dataset</i>	65
5.4	Hasil Klasifikasi dari Aspek Jumlah Kategori	66
5.4.1	Hasil Klasifikasi untuk Data Dokumen Hukum.....	66
5.4.2	Hasil Klasifikasi untuk Data Artikel Media Massa.....	67
5.4.3	Hasil Klasifikasi untuk Data 20Newsgroups <i>Dataset</i>	70
5.5	Pengaruh <i>Unlabeled Documents</i> terhadap Akurasi Klasifikasi.....	73
5.5.1	Hasil Klasifikasi untuk Data Dokumen Hukum.....	73
5.5.2	Hasil Klasifikasi untuk Data Artikel Media Massa.....	75
5.5.3	Hasil Klasifikasi untuk Data 20Newsgroups <i>Dataset</i>	78
5.6	Rangkuman Hasil Percobaan.....	80
BAB 6	PENUTUP	83
6.1	Kesimpulan.....	83
6.2	Kendala.....	84
6.3	Saran	84
	DAFTAR PUSTAKA	86

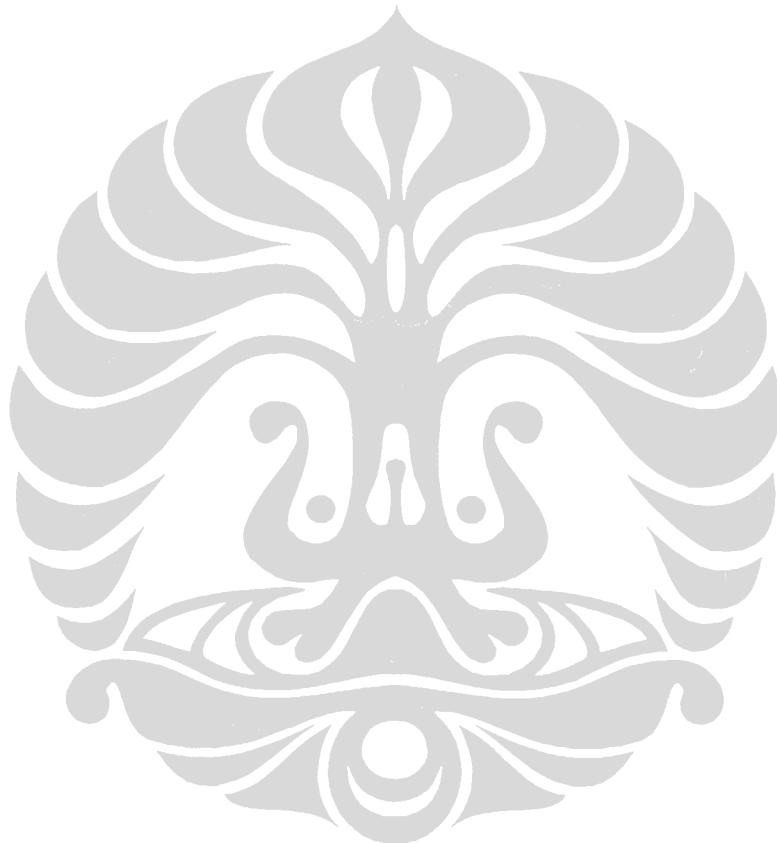
DAFTAR TABEL

Tabel 3.1 Daftar Kategori dan Jumlah Dokumen yang Digunakan	20
Tabel 4.1 Variasi Jenis Fitur	44
Tabel 5.1 Variabel Percobaan	53
Tabel 5.2 Hasil Pemilihan Fitur pada Dokumen Hukum.....	57
Tabel 5.3 Hasil Pemilihan Fitur pada Artikel Media Massa.....	59
Tabel 5.4 Hasil Pemilihan Fitur pada 20Newsgroups <i>Dataset</i>	61
Tabel 5.5 Kesalahan Klasifikasi pada Dokumen Hukum	67
Tabel 5.6 Kesalahan Klasifikasi pada Artikel Media Massa	69
Tabel 5.7 Kesalahan Klasifikasi dengan Metode Naïve Bayes pada 20Newsgroups <i>Dataset</i>	72
Tabel 5.8 Pengaruh <i>Unlabeled Documents</i> pada Dokumen Hukum.....	74
Tabel 5.9 Pengaruh <i>Unlabeled Documents</i> pada Artikel Media Massa.....	76
Tabel 5.10 Pengaruh <i>Unlabeled Documents</i> pada 20Newsgroups <i>Dataset</i>	78

DAFTAR GAMBAR

Gambar 2.1 Tahapan Algoritma Klasifikasi Naïve Bayes	11
Gambar 2.2 Tahapan Algoritma Klasifikasi Expectation Maximization.....	14
Gambar 3.1 Perancangan Percobaan Klasifikas Dokumen Teks	18
Gambar 3.2 <i>Term Documents Matrix</i>	24
Gambar 4.1 <i>Pseudocode</i> Proses <i>Converting</i> Dokumen	39
Gambar 4.2 Hasil Keluaran dari Text Mining Tools 1.1.42	40
Gambar 4.3 <i>Pseudocode</i> Proses <i>Filtering</i> Dokumen	41
Gambar 4.4 <i>Pseudocode</i> Pemilihan Fitur.....	43
Gambar 4.5 <i>Pseudocode</i> <i>Folding</i> Dokumen	44
Gambar 4.6 Format Penyimpanan <i>Term Documents Matrix</i> dengan Informasi <i>Presence</i>	45
Gambar 4.7 <i>Pseudocode</i> Pembuatan <i>Term Documents Matrix</i>	46
Gambar 4.8 Format Berkas ARFF	47
Gambar 4.9 <i>Pseudocode</i> Klasifikasi Dokumen Teks Menggunakan Naïve Bayes	49
Gambar 4.10 Hasil Keluaran Klasifikasi Dokumen Teks dengan Naïve Bayes	49
Gambar 4.11 <i>Pseudocode</i> Konversi ARFF ke <i>Dataset MinorThird</i>	50
Gambar 4.12 <i>Pseudocode</i> Klasifikasi Dokumen Teks Menggunakan Expectation Maximization	51
Gambar 4.13 Hasil Keluaran Klasifikasi Dokumen Teks dengan Expectation Maximization	52
Gambar 5.1 Hasil Pemilihan Fitur pada Dokumen Hukum	58
Gambar 5.2 Hasil Pemilihan Fitur pada Artikel Media Massa	60
Gambar 5.3 Hasil Pemilihan Fitur pada 20Newsgroups <i>Dataset</i>	62
Gambar 5.4 Pengaruh Penggunaan Jenis Fitur pada Dokumen Hukum	63
Gambar 5.5 Pengaruh Penggunaan Jenis Fitur pada Artikel Media Massa	64
Gambar 5.6 Pengaruh Penggunaan Jenis Fitur pada 20Newsgroups <i>Dataset</i>	65
Gambar 5.7 Pengaruh Jumlah Kategori pada Dokumen Hukum.....	66

Gambar 5.8 Pengaruh Jumlah Kategori pada Artikel Media Massa	69
Gambar 5.9 Pengaruh Jumlah Kategori pada 20Newsgroups <i>Dataset</i>	71
Gambar 5.10 Pengaruh <i>Unlabeled Documents</i> pada Dokumen Hukum.....	75
Gambar 5.11 Pengaruh <i>Unlabeled Documents</i> pada Artikel Media Massa.....	77
Gambar 5.12 Pengaruh <i>Unlabeled Documents</i> pada 20Newsgroups <i>Dataset</i>	79



DAFTAR PERSAMAAN

Persamaan (2.1) Probabilitas Kelas c jika diketahui Dokumen d	9
Persamaan (2.2) Probabilitas Kelas c jika diketahui Dokumen d dengan Perhitungan Hasil Perkalian dari Probabilitas Kemunculan Semua Kata pada Dokumen d	10
Persamaan (2.3) Probabilitas Kata w jika diketahui Kategori c	10
Persamaan (2.4) Probabilitas Kategori c Persamaan (2.5) Probabilitas Kata w jika diketahui Kategori c dengan <i>Laplacian</i> <i>Smoothing</i>	10
Persamaan (2.6) Penentuan Kategori Hasil Klasifikasi	11
Persamaan (2.7) Probabilitas Keseluruhan Dokumen <i>Training</i>	12
Persamaan (2.8) Perhitungan <i>Log Likelihood</i>	12
Persamaan (2.9) Perhitungan <i>Complete Log Likelihood</i>	13
Persamaan (2.10) Probabilitas Kategori c jika diketahui Dokumen d pada <i>Expectation</i> <i>Step EM</i>	13
Persamaan (2.11) Probabilitas Kata w jika diketahui Kategori c pada <i>Maximization</i> <i>Step EM</i>	14
Persamaan (2.12) Probabilitas Kategori c pada <i>Maximization Step EM</i>	14

DAFTAR LAMPIRAN

LAMPIRAN 1 HASIL KLASIFIKASI DOKUMEN	87
LAMPIRAN 2 CONTOH DATA YANG DIPAKAI.....	102
LAMPIRAN 3 DAFTAR <i>STOPWORDS</i>	116

