

**IMPLEMENTASI METODE FITUR EKSTRAKSI DAN
ALGORITMA SUPERVISED LEARNING DALAM
MENGIDENTIFIKASI JENIS KELAMIN
BERDASARKAN NAMA**

SKRIPSI SARJANA

Oleh

Muhammad Rizkiansyah
183112706450091



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI KOMUNIKASI DAN
INFORMATIKA
UNIVERSITAS NASIONAL
2022**

**IMPLEMENTASI METODE FITUR EKSTRAKSI DAN
ALGORITMA SUPERVISED LEARNING DALAM
MENGIDENTIFIKASI JENIS KELAMIN
BERDASARKAN NAMA**

SKRIPSI SARJANA

Karya ilmiah sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik Teknologi Informatika dari Fakultas Teknologi Komunikasi dan Informatika

Oleh

Muhammad Rizkiansyah
183112706450091



PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI KOMUNIKASI DAN
INFORMATIKA
UNIVERSITAS NASIONAL
2022

**HALAMAN PENGESAHAN
TUGAS SARJANA**

**IMPLEMENTASI METODE FITUR EKSTRAKSI DAN
ALGORITMA SUPERVISED LEARNING DALAM
MENGIDENTIFIKASI JENIS KELAMIN
BERDASARKAN NAMA**



Pembimbing I

(Ratih Titi Komala Sari, ST, MM, MMSI)
NID. 0103150850

Pembimbing II

(Albaar Rubhasy, S.Si, MTI)
NID. 050020069

KATA PENGANTAR

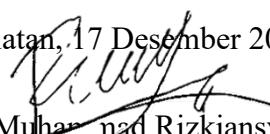
Puji dan syukur penulis panjatkan kepada Allah SWT Tuhan Yang Maha Esa yang telah memberikan rahmat dan karunia sehingga penulis dapat menyelesaikan skripsi dengan judul **“Implementasi Metode Fitur Ekstraksi dan Algoritma Supervised Learning dalam Mengidentifikasi Jenis Kelamin berdasarkan Nama”** sebagai salah satu syarat kelulusan Program Studi Sarjana Informatika Fakultas Teknologi Komunikasi dan Informatika.

Penelitian dan penulisan skripsi ini tidak terlepas dari bantuan berbagai pihak, oleh karena itu penulis menyampaikan banyak terima kasih terutama kepada dosen pembimbing Tugas Akhir, ibu Ratih Titi Komala Sari, ST, MM, MMSI dan bapak Albaar Rubhasy, S.Si, MTI yang telah meluangkan banyak waktu, tenaga, pikiran, bimbingan, arahan, motivasi serta memaklumi segala kekurangan penulis selama penelitian tugas akhir dan penyusunan skripsi. Penulis juga mengucapkan banyak terima kasih kepada:

1. Bapak dan Mamah selaku orangtua penulis yang telah banyak memberi dukungan dan doa yang tak terhitung.
2. Seluruh dosen pengajar di program studi Informatika FTKI maupun dosen di program studi lain, yang memberikan banyak pengetahuan dan ilmu.
3. Teman-teman seangkatan dan sehimpunan yang telah membantu dan memberikan dukungan.
4. Kaka dan sahabat-sahabat yang telah memberikan banyak dukungan secara mental maupun fisik.

Akhir kata, semoga Allah SWT Tuhan Yang Maha Esa membala kebaikan dan bantuan yang telah diberikan dengan hal yang lebih baik. Penulis mengharapkan kritik dan saran yang bersifat membangun dan semoga skripsi ini dapat memberikan manfaat dibidang teknologi informatika.

Tangerang Selatan, 17 Desember 2022


Muhamad Rizkiansyah

HALAMAN PERNYATAAN PERSETUJUAN

PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN

AKADEMIS

Sebagai sivitas akademik Program Studi Teknik Informatika, Fakultas Teknologi Komunikasi dan Informatika, saya yang bertanda tangan di bawah ini:

Nama : Muhammad Rizkiansyah
NIM : 183112706450091

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Fakultas Teknologi Komunikasi dan Informatika, Hak Bebas Royalti Noneksklusif (*Non-exclusive Royalty Free Right*) atas karya ilmiah saya yang berjudul:

IMPLEMENTASI METODE FITUR EKSTRAKSI DAN ALGORITMA SUPERVISED LEARNING DALAM MENGIDENTIFIKASI JENIS KELAMIN BERDASARKAN NAMA

Beserta perangkat yang ada (jika diperlukan). Dengan Hak ini Fakultas Teknologi Komunikasi dan Informatika berhak menyimpan, mengalihmedia/formatkan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan mempublikasikan 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 : Tangerang Selatan

Pada tanggal : 17 Desember 2022

Yang menyatakan



(Muhammad Rizkiansyah)

HALAMAN PENGESAHAN

TUGAS AKHIR

IMPLEMENTASI METODE FITUR EKSTRAKSI DAN ALGORITMA
SUPERVISED LEARNING DALAM MENGIDENTIFIKASI JENIS
KELAMIN BERDASARKAN NAMA



Dosen Pembimbing 1

(Ratih Titi Komalasari, S. T, MM., MMSI)

Dosen Pembimbing 2

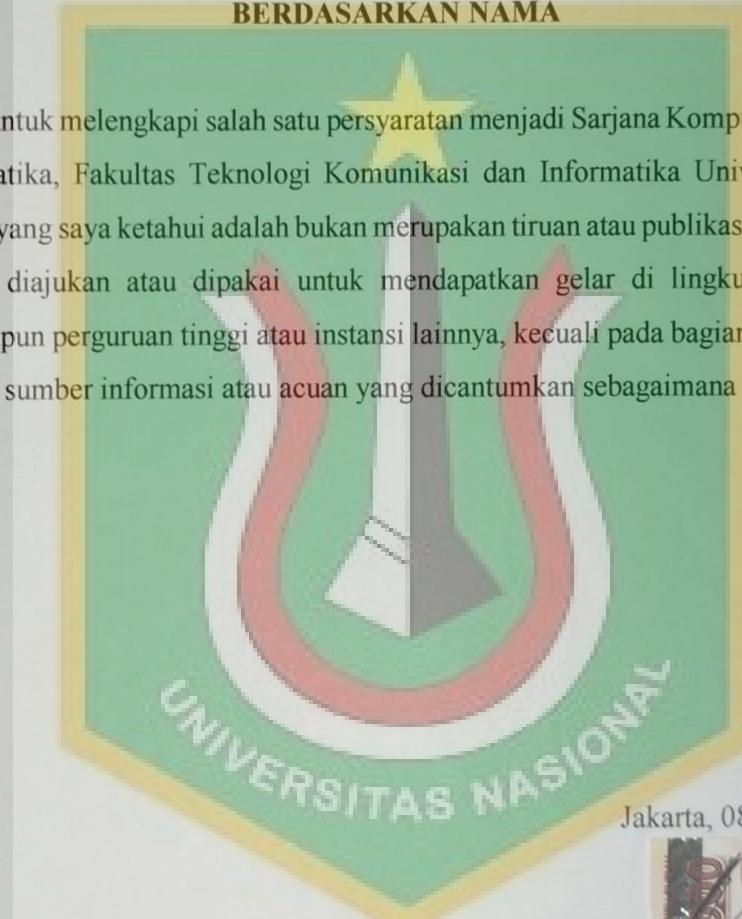
(Albaar Rubhasy, S.Si, MTI)

PERNYATAAN KEASLIAN TUGAS AKHIR

Saya menyatakan dengan sesungguhnya bahwa Tugas Akhir dengan judul :

IMPLEMENTASI METODE FITUR EKSTRAKSI DAN ALGORITMA SUPERVISED LEARNING DALAM MENIDENTIFIKASI JENIS KELAMIN BERDASARKAN NAMA

Yang dibuat untuk melengkapi salah satu persyaratan menjadi Sarjana Komputer pada Program Studi Informatika, Fakultas Teknologi Komunikasi dan Informatika Universitas Nasional, sebagaimana yang saya ketahui adalah bukan merupakan tiruan atau publikasi dari Tugas Akhir yang pernah diajukan atau dipakai untuk mendapatkan gelar di lingkungan Universitas Nasional maupun perguruan tinggi atau instansi lainnya, kecuali pada bagian – bagian tertentu yang menjadi sumber informasi atau acuan yang dicantumkan sebagaimana mestinya.



Jakarta, 08 Maret 2023



Muhammad Rizkiansyah
183122706450091

LEMBAR PERSETUJUAN TUGAS AKHIR

Tugas Akhir dengan judul :

IMPLEMENTASI METODE FITUR EKSTRAKSI DAN ALGORITMA SUPERVISED LEARNING DALAM MENGIDENTIFIKASI JENIS KELAMIN

BERDASARKAN NAMA

Dibuat untuk melengkapi salah satu persyaratan menjadi Sarjana Komputer pada Program Studi Informatika, Fakultas Teknologi Komunikasi dan Informatika Universitas Nasional. Tugas Akhir ini diujikan pada Sidang Akhir Semester Ganjil 2022-2023 pada tanggal 22 Februari Tahun 2023



Dosen Pembimbing 1

Ratih Titi Komalasari, S. T.,
MM., MMSI

NID. 0103150850

Ketua Program Studi

Ratih Titi Komalasari, S. T.,
MM., MMSI

NID. 0103150850

LEMBAR PERSETUJUAN JUDUL YANG TIDAK ATAU YANG DIREVISI

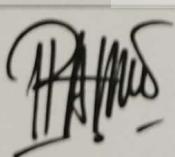
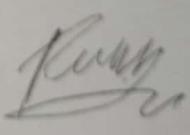
Nama : Muhammad Rizkiansyah
NPM : 183112706450091
Fakultas/Akademi : Fakultas Teknologi Komunikasi dan Informatika
Program Studi : Informatika
Tanggal Sidang : 22 Februari 2023

JUDUL DALAM BAHASA INDONESIA :

IMPLEMENTASI METODE FITUR EKSTRAKSI DAN ALGORITMA SUPERVISED LEARNING DALAM MENGINDEKTIKASI JENIS KELAMIN BERDASARKAN NAMA

JUDUL DALAM BAHASA INGGRIS :

IMPLEMENTATION OF FEATURE EXTRACTION METHOD AND SUPERVISED LEARNING ALGORITHM IN IDENTIFYING GENDER BASED ON NAME

TANDA TANGAN DAN TANGGAL		
Pembimbing 1	Ka. Prodi	Mahasiswa
TGL : 	TGL : 	TGL : 13 - 03 - 2023 

LEMBAR PERSETUJUAN JUDUL YANG TIDAK ATAU YANG DIREVISI

Nama : Muhammad Rizkiansyah
NPM : 183112706450091
Fakultas/Akademi : Fakultas Teknologi Komunikasi dan Informatika
Program Studi : Informatika
Tanggal Sidang : 22 Februari 2023

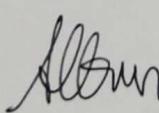
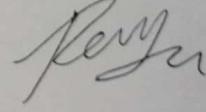
JUDUL DALAM BAHASA INDONESIA :

IMPLEMENTASI METODE FITUR EKSTRAKSI DAN ALGORITMA SUPERVISED LEARNING DALAM MENGINDEKTIKASI JENIS KELAMIN BERDASARKAN NAMA

JUDUL DALAM BAHASA INGGRIS :

IMPLEMENTATION OF FEATURE EXTRACTION METHOD AND SUPERVISED LEARNING ALGORITHM IN IDENTIFYING GENDER BASED ON NAME

TANDA TANGAN DAN TANGGAL

Pembimbing 2	Ka. Prodi	Mahasiswa
TGL : 10-03-2023 	TGL : 	TGL : 10-03-2023 

ABSTRAK

Pemegang data memiliki dokumen terkait data personal akan tetapi tidak adanya variabel gender dalam dokumen tersebut. Dalam hal ini, memungkinkan pemilik data mengklasifikasikan variabel gender berdasarkan nama yang ada secara manual. Mengklasifikasikan dokumen secara manual dinilai tidak seefisien seperti dulu, karena jumlah data yang semakin meningkat. Algoritma supervised learning yang ada pada machine learning dapat berperan, sebagai cara alternatif dalam pengklasifikasian dokumen. Penelitian ini dilakukan untuk mencari model yang terbaik dalam mengidentifikasi jenis kelamin berdasarkan nama, yang diimplementasikan ke dalam aplikasi prediksi berbasis web, dengan menggunakan fitur ekstraksi countvectorizer dan pemanfaatan n-gram serta membandingkan kedua algoritma supervised learning yaitu logistic regression dan multinomial naive bayes. Hasil dari penelitian ini didapatkan model terbaik yaitu model logistic regression pada rentang 2-12 gram dengan split data 80:20 yang memiliki tingkat akurasi 94.76%, dan berdasarkan uji validasi model menggunakan confusion matrix logistic regression memperoleh 0.95 f1-score pada semua labeling, beserta dari hasil uji prediksi yang mendapatkan kesalahan prediksi tersedikit yaitu 28. Maka dari itu model logistic regression dengan split data 80:20 yang akan diterapkan ke dalam aplikasi prediksi berbasis web.

Kata Kunci: Identifikasi, Fitur Ekstraksi, Model Klasifikasi, Confusion Matrix, Aplikasi Prediksi.



ABSTRACT

The data owner has documents containing personal data, but there is no mention of gender in those records. In this instance, it enables the data owner to manually categorize gender variables based on names that already exist. The growing volume of data makes manual document classification less effective than it formerly was. As a substitute method of classifying documents, the supervised learning technique used in machine learning may be useful. By comparing the two supervised learning algorithms, logistic regression and multinomial naive Bayes, and using the countvectorizer extraction feature and n-grams, this research sought to identify the most effective model for classifying gender based on name. This model was then implemented into a web-based prediction application. The results of this study obtained the best model, namely the logistic regression model at a susceptibility of 2-12 grams with a data split of 80:20 which had an accuracy rate of 94.76%, and based on the model validation test using a confusion matrix logistic regression obtained 0.95 f1-score on all labeling, along with from the results of the prediction test that gets the least prediction error, namely 28. Therefore, the logistic regression model with an 80:20 data split will be applied to a web-based prediction application.

Keywords: Identification, Feature Extraction, Classification Model, Confusion Matrix, Prediction Application.



DAFTAR ISI

HALAMAN PERNYATAAN ORISINALITAS	i
HALAMAN PENGESAHAN.....	ii
TUGAS SARJANA	ii
KATA PENGANTAR.....	iii
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS	iv
ABSTRAK	v
ABSTRACT	vi
DAFTAR ISI.....	vii
DAFTAR TABEL	x
DAFTAR GAMBAR.....	xi
BAB I.....	1
PENDAHULUAN.....	1
1.1. Latar Belakang	1
1.2. Perumusan Masalah.....	2
1.3. Tujuan Penelitian	2
1.4. Manfaat Penelitian	3
1.5. Batasan Masalah.....	3
BAB II	4
TINJAUAN PUSTAKA.....	4
2.1. Landasan Teori.....	4
2.1.1. Data terpilah.....	4
2.1.2. Identifikasi jenis kelamin berdasarkan nama	4
2.1.3. Data Preprocessing.....	4
2.1.4. Fitur Ekstraksi	5

2.1.5. Supervised learning.....	7
2.1.6. Logistic Regression	8
2.1.7. Multinomial Naive Bayes.....	8
2.1.8. Evaluasi	8
2.2. Studi Literatur	10
2.2.1. Matriks Penelitian	13
BAB III.....	15
METODE PENELITIAN	15
3.1. Teknik Pengumpulan Data.....	15
3.2. Sumber Data	15
3.3. Perancangan Sistem	16
3.3.1. Preprocessing data	16
3.3.2. Split Data	17
3.3.3. Fitur Ekstraksi	17
3.3.4. Modeling	17
3.3.5. Evaluasi Model	18
3.4. Pengujian Sistem	18
3.5. Implementasi Sistem	18
BAB IV	19
HASIL DAN DISKUSI	19
4.1. Pembahasan Data dan Preprocessing.....	19
4.1.1. Data	19
4.1.2. Preprocessing.....	20
4.2. Pembahasan Split Data	22
4.3. Pembahasan Fitur dan Modeling.....	23
4.3.1. Fitur	23
4.3.2. Modeling	24
4.4. Evaluasi Model	25
4.5. Pengujian Sistem	28
4.6. Implementasi Model.....	29
4.6.1. Tampilan implementasi model pada aplikasi web	29
4.6.2. Uji prediksi model pada aplikasi berbasis web	31
BAB V.....	32

KESIMPULAN DAN SARAN	32
5.1. Kesimpulan	32
5.2. Saran.....	32
DAFTAR PUSTAKA	34



DAFTAR TABEL

Tabel 2.1 Tahap vektorisasi bag-of-word.....	6
Tabel 2.2 Tabel yang dihasilkan confusion matrix	9
Tabel 2.3 Tabel perhitungan confusion matrix.....	9
Tabel 2.4 Matrix penelitian	13
Tabel 3.3 Parameter yang digunakan	17
Tabel 3.4 Representasi hasil.....	18
Tabel 4.1 Tampilan dataset 1.....	19
Tabel 4.2 Tampilan dataset 2.....	19
Tabel 4.3 Hasil transformasi data pada dataset 1	20
Tabel 4.4 Hasil transformasi data pada dataset 2	20
Tabel 4.5 Hasil integration data	21
Tabel 4.6 Sebelum preprocessing data.....	21
Tabel 4.7 Sesudah preprocessing data.....	22
Tabel 4.8 Hasil split data.....	22
Tabel 4.9 Hasil term frekuensi beserta pemanfaatan n-gram	23
Tabel 4.10 Hasil nilai rata-rata 2 sampai 12 gram (LR).....	24
Tabel 4.11 Hasil nilai rata-rata 2 sampai 12 gram (MNB).....	24
Tabel 4.12 Data nilai hasil confusion matrix setiap model	26
Tabel 4.13 Nilai validasi dari setiap model pada pembagian data 70:30	26
Tabel 4.14 Nilai validasi dari setiap model pada pembagian data 80:20	27
Tabel 4.15 Hasil uji prediksi	28
Tabel 4.16 Persentase uji prediksi.....	28

DAFTAR GAMBAR

Gambar 3.2 Rancangan sistem penelitian.....	16
Gambar 4.1 Heatmap confusion matrix lr (a) 70:30 (b) 80:20	25
Gambar 4.2 Heatmap confusion matrix mnb (a) 70:20 (b) 80:20	25
Gambar 4.3 Tampilan home	29
Gambar 4.4 Tampilan halaman prediksi dokumen.....	30
Gambar 4.5 Tampilan halaman prediksi satuan	30
Gambar 4.6 Uji prediksi pada web	31

