

**KLASIFIKASI GENDER BERDASARKAN NAMA
INDONESIA MENGGUNAKAN MODEL INDOBERT
DARI INDONLU: STUDI KASUS PADA CUSTOMER
PROFILE KOMPAS GRAMEDIA**



LAPORAN MBKM MAGANG

**LEONARDO TYOES HUIBU
00000065503**

**PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK DAN INFORMATIKA
UNIVERSITAS MULTIMEDIA NUSANTARA
TANGERANG
2025**

**KLASIFIKASI GENDER BERDASARKAN NAMA
INDONESIA MENGGUNAKAN MODEL INDOBERT
DARI INDONLU: STUDI KASUS PADA CUSTOMER
PROFILE KOMPAS GRAMEDIA**



LAPORAN MBKM MAGANG

UMN
LEONARDO TYOES HUIBU
00000065503

UNIVERSITAS
MULTIMEDIA
PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK DAN INFORMATIKA
UNIVERSITAS MULTIMEDIA NUSANTARA

TANGERANG
2025

HALAMAN PERNYATAAN ORISINALITAS TIDAK PLAGIAT

Dengan ini saya,

Nama : Leonardo Tyoes Huibu
NIM : 00000065503
Program Studi : Informatika

Menyatakan dengan sesungguhnya bahwa Laporan MBKM Magang saya yang berjudul:

Klasifikasi Gender Berdasarkan Nama Indonesia Menggunakan Model IndoBERT dari IndoNLU: Studi Kasus pada Customer Profile Kompas Gramedia

merupakan hasil karya saya sendiri, bukan merupakan hasil plagiat, dan tidak pula dituliskan oleh orang lain; Semua sumber, baik yang dikutip maupun dirujuk, telah saya cantumkan dan nyatakan dengan benar pada bagian Daftar Pustaka.

Jika di kemudian hari terbukti ditemukan kecurangan/penyimpangan, baik dalam pelaksanaan skripsi maupun dalam penulisan laporan karya ilmiah, saya bersedia menerima konsekuensi untuk dinyatakan TIDAK LULUS. Saya juga bersedia menanggung segala konsekuensi hukum yang berkaitan dengan tindak plagiarisme ini sebagai kesalahan saya pribadi dan bukan tanggung jawab Universitas Multimedia Nusantara.

Tangerang, 19 Juni 2025



(Leonardo Tyoes Huibu)

HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : Leonardo Tyoes Huibu
NIM : 00000065503
Program Studi : Informatika
Jenjang : S1
Jenis Karya : Laporan MBKM Magang

Menyatakan dengan sesungguhnya bahwa:

- Saya bersedia memberikan izin sepenuhnya kepada Universitas Multimedia Nusantara untuk mempublikasikan hasil karya ilmiah saya di repositori Knowledge Center, sehingga dapat diakses oleh Civitas Akademika/Publik. Saya menyatakan bahwa karya ilmiah yang saya buat tidak mengandung data yang bersifat konfidensial dan saya juga tidak akan mencabut kembali izin yang telah saya berikan dengan alasan apapun.
- Saya tidak bersedia karena dalam proses pengajuan untuk diterbitkan ke jurnal/konferensi nasional/internasional (dibuktikan dengan *letter of acceptance*)**.

Tangerang, 19 Juni 2025

Yang menyatakan

Leonardo Tyoes Huibu

UNIVERSITAS
MULTIMEDIA
NUSANTARA

** Jika tidak bisa membuktikan LoA jurnal/HKI selama enam bulan ke depan, saya bersedia mengizinkan penuh karya ilmiah saya untuk diunggah ke KC UMN dan menjadi hak institusi UMN.

Halaman Persembahan / Motto



”A good name is to be more desired than great wealth, Favor is better than silver and gold.”

Proverbs 22:1 (NASB)

UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA

KATA PENGANTAR

Puji dan syukur panjatkan ke hadirat Tuhan Yang Maha Esa atas limpahan rahmat dan karunia-Nya, sehingga dapat menyelesaikan laporan magang ini dengan baik. Tugas Akhir ini tidak hanya disusun untuk memenuhi syarat akademik maupun kebutuhan perusahaan, tetapi juga sebagai upaya untuk memperdalam pemahaman terhadap konsep deep learning dan mengeksplorasi bagaimana model dengan struktur yang kompleks mampu menangani permasalahan nyata secara efektif. Ucapan terima kasih disampaikan kepada pihak-pihak sebagai berikut:

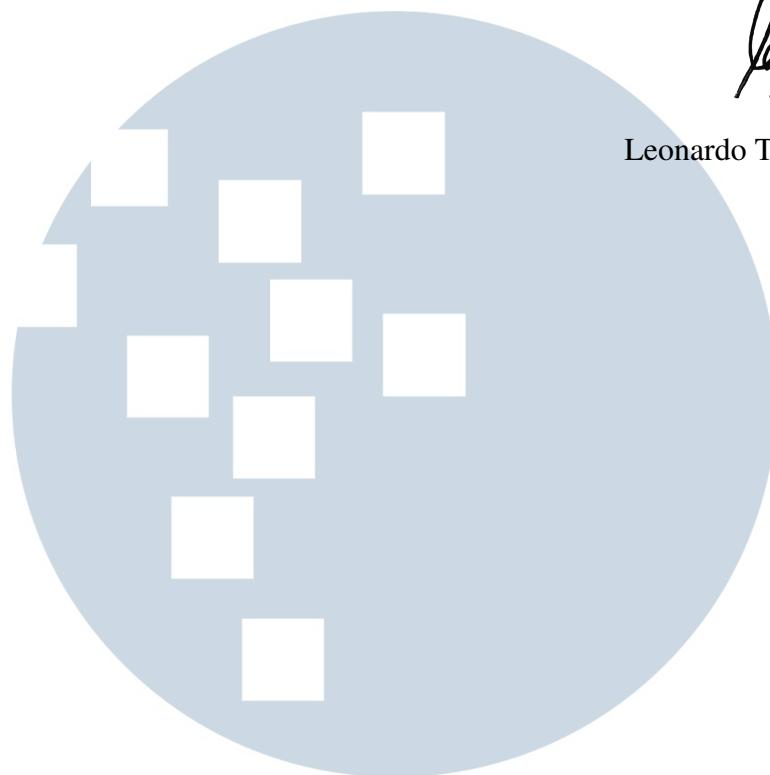
1. Bapak Dr. Ir. Andrey Andoko, M.Sc., selaku Rektor Universitas Multimedia Nusantara.
2. Bapak Dr. Eng. Niki Prastomo, S.T., M.Sc., selaku Dekan Fakultas Teknik dan Informatika Universitas Multimedia Nusantara.
3. Bapak Arya Wicaksana, S.Kom., M.Eng.Sc., OCA, selaku Ketua Program Studi Informatika Universitas Multimedia Nusantara.
4. Ibu Sy Yuliani Yakub, S.Kom., M.T. PhD, sebagai Pembimbing pertama yang telah banyak meluangkan waktu untuk memberikan bimbingan, arahan dan motivasi atas terselesainya tesis ini. memberikan bimbingan atas terselesainya laporan magang ini.
5. Kepada Bapak Agung Wicaksono sebagai Supervisor, serta Bapak Falah Novayanda Adlin sebagai Mentor, atas dukungan moral, bantuan dalam perancangan awal, dan masukan yang sangat membantu dalam proses diskusi dan penyusunan proyek ini.
6. Orang Tua saya yang telah memberikan bantuan dukungan material dan moral, sehingga penulis dapat menyelesaikan tesis ini.

Harapannya, karya ilmiah ini dapat mendorong lebih banyak generasi muda untuk tertarik melakukan analisis dan mengembangkan proyek-proyek lanjutan berbasis deep learning dan machine learning, serta menjadi referensi yang bermanfaat bagi penelitian selanjutnya dalam menerapkan model ini pada berbagai jenis tugas yang berbeda.

Tangerang, 19 Juni 2025



Leonardo Tyoes Huibu



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA

**KLASIFIKASI GENDER BERDASARKAN NAMA INDONESIA
MENGGUNAKAN MODEL INDOBERT DARI INDONLU: STUDI KASUS
PADA CUSTOMER PROFILE KOMPAS GRAMEDIA**

Leonardo Tyoes Huibu

ABSTRAK

Profil pelanggan memberikan keuntungan strategis bagi sebuah toko dalam merancang pendekatan yang tepat guna meningkatkan profit. Salah satu elemen penting dalam profil pelanggan adalah distribusi jenis kelamin. Memahami distribusi ini dapat memberikan wawasan yang bernilai dalam menentukan jenis promosi serta produk yang perlu diutamakan. Kompas Gramedia mengidentifikasi kebutuhan ini dalam tim pemasaran mereka, namun data jenis kelamin yang tersedia masih sangat terbatas. Pada tahap awal, model *Random Forest* telah dikembangkan untuk klasifikasi jenis kelamin berdasarkan nama-nama Indonesia, namun akurasi dan *F1 score* yang dicapai hanya berkisar antara 70%–72%, yang dianggap belum memadai. Maka dengan alasan tersebut, diperlukan model yang bisa mengatasi permasalahan yang ada. Dikembangkanlah model baru berbasis *Deep Learning* bernama *IndoBERT*. *IndoBERT* adalah model berbasis arsitektur *Transformer* pada bagian *Encoder*, yang terbukti efektif dalam berbagai tugas klasifikasi, terutama dalam konteks Bahasa Indonesia. Dengan menggunakan *IndoBERT*, akurasi dan *F1 score* dalam klasifikasi jenis kelamin meningkat secara signifikan hingga mencapai 94%.

Kata kunci: *IndoBERT*, Jenis Kelamin, Klasifikasi Teks, Kompas Gramedia, Nama Indonesia



**GENDER CLASSIFICATION BASED ON INDONESIAN NAMES USING
THE INDOBERT MODEL FROM INDONLU: A CASE STUDY ON KOMPAS
GRAMEDIA'S CUSTOMER PROFILE**

Leonardo Tyoes Huibu

ABSTRACT

Customer profiling provides a strategic advantage for a store in designing the right approach to increase profit. One important element in customer profiling is gender distribution. Understanding this distribution can offer valuable insights in determining the types of promotions and products that should be prioritized. Kompas Gramedia identified this need within their marketing team; however, the available gender data was still very limited. In the initial phase, a Random Forest model was developed to classify gender based on Indonesian names, but the achieved accuracy and F1 score only ranged between 70%–72%, which was considered insufficient. For this reason, a more capable model was needed to address the issue. A new deep learning-based model called IndoBERT was then developed. IndoBERT is a model based on a transformer architecture at the encoder level, which has proven effective in various classification tasks, especially in the context of the Indonesian language. By using IndoBERT, the accuracy and F1 score in gender prediction significantly improved, reaching up to 94%.

Keywords: Gender Prediction, IndoBERT, Indonesian Names, Kompas Gramedia, Text Classification

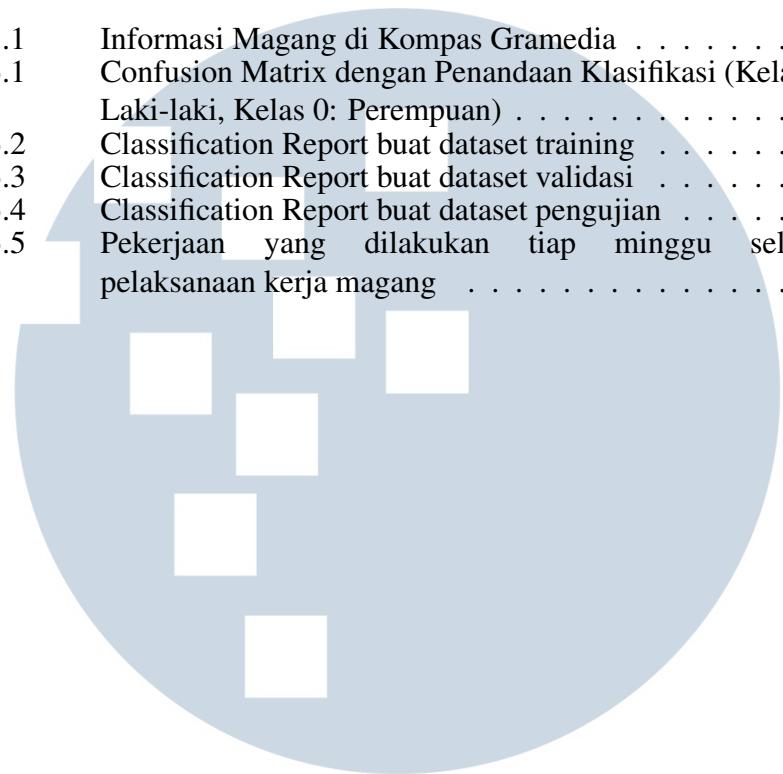


DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PERNYATAAN ORISINALITAS	ii
HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH	iii
HALAMAN PERSEMBAHAN/MOTO	iv
KATA PENGANTAR	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI	ix
DAFTAR TABEL	x
DAFTAR GAMBAR	xi
DAFTAR KODE	xii
DAFTAR RUMUS	xiii
DAFTAR LAMPIRAN	xiv
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Maksud dan Tujuan Kerja Magang	5
1.3 Waktu dan Prosedur Pelaksanaan Kerja Magang	5
BAB 2 GAMBARAN UMUM PERUSAHAAN	7
2.1 Sejarah Singkat Perusahaan	7
2.2 Visi dan Misi Perusahaan	11
2.3 Struktur Organisasi Perusahaan	12
BAB 3 PELAKSANAAN KERJA MAGANG	15
3.1 Kedudukan dan Koordinasi	15
3.2 Tugas yang Dilakukan	16
3.3 Uraian Pelaksanaan Magang	17
3.3.1 pengumpulan data	18
3.3.2 Pra-pemrosesan	21
3.3.3 Fungsi dan Utilitas Evaluasi	36
3.3.4 Fase pelatihan dan validasi	43
3.3.5 Fase testing dan penyimpanan mode	47
3.3.6 Evaluasi Model	48
3.3.7 Penerapan server	52
3.3.8 Pelaksanaan Magang	61
3.4 Kendala dan Solusi yang Ditemukan	62
BAB 4 SIMPULAN DAN SARAN	67
4.1 Simpulan	67
4.2 Saran	67
DAFTAR PUSTAKA	69

DAFTAR TABEL

Tabel 1.1	Informasi Magang di Kompas Gramedia	6
Tabel 3.1	Confusion Matrix dengan Penandaan Klasifikasi (Kelas 1: Laki-laki, Kelas 0: Perempuan)	41
Tabel 3.2	Classification Report buat dataset training	49
Tabel 3.3	Classification Report buat dataset validasi	51
Tabel 3.4	Classification Report buat dataset pengujian	52
Tabel 3.5	Pekerjaan yang dilakukan tiap minggu selama pelaksanaan kerja magang	61



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA

DAFTAR GAMBAR

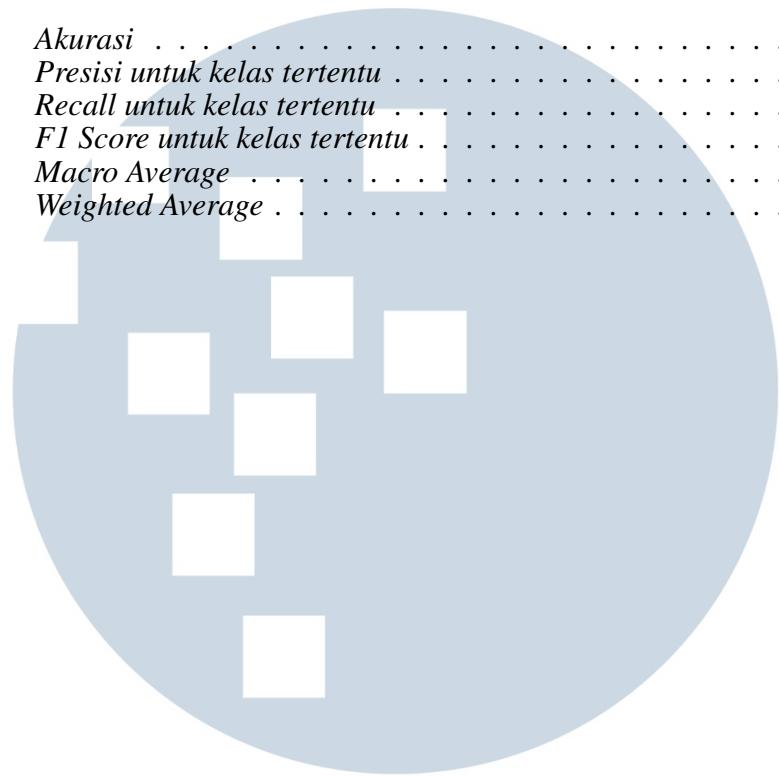
Gambar 1.1	Divisi Kompas Gramedia, Grup Retail & Publishing	1
Gambar 1.2	The 5 vs of <i>Big Data</i>	2
Gambar 1.3	Hierarki metode dalam kecerdasan buatan: Artificial Intelligence → Machine Learning → Pembelajaran Fitur (Representation Learning) → Deep Learning → Generative AI.	3
Gambar 2.1	Logo Kompas Gramedia	7
Gambar 2.2	Logo KG Media	8
Gambar 2.3	Logo KG Hospitality	9
Gambar 2.4	Logo KG Education	9
Gambar 2.5	Logo KG Retail & Publishing	9
Gambar 2.6	Logo KG Manufacture	10
Gambar 2.7	Logo KG Event & Venue	10
Gambar 2.8	Logo KG Property	10
Gambar 2.9	Logo KG Digital	11
Gambar 2.10	Struktur dari Grup Retail dan Publishing	12
Gambar 2.11	Struktur Finance dan Management Directorate	13
Gambar 3.1	Bagan proses pembuatan model IndoBERT prediksi kelamin dari nama Indonesia	18
Gambar 3.2	Bagan Kerja untuk pengumpulan data	19
Gambar 3.3	Sebagian dataset untuk prediksi <i>gender</i> berdasarkan nama	19
Gambar 3.4	Bagan Kerja untuk Pra-pemrosesan	21
Gambar 3.5	Total nilai yang hilang dalam dataset, baik pada kolom gender, nama, atau keduanya	21
Gambar 3.6	Total karakter khusus dalam nama pelanggan	21
Gambar 3.7	Tabel dataset yang sudah bersih	28
Gambar 3.8	pie chart distribusi kelamin pada dataset yang sudah bersih	28
Gambar 3.9	Bagan kerja untuk fungsi dan utilitas evaluasi	36
Gambar 3.10	Bagan kerja magang fase pelatihan dan validasi	43
Gambar 3.11	Bagan kerja magang fase testing	47
Gambar 3.12	Beberapa versi model yang telah dibuatkan	48
Gambar 3.13	Beberapa versi model yang telah dibuatkan	49
Gambar 3.14	Hasil confusion matrix untuk Dataset pelatihan	49
Gambar 3.15	Hasil confusion matrix untuk Dataset Validasi	50
Gambar 3.16	Hasil confusion matrix untuk Dataset Pengujian	51
Gambar 3.17	Bagan kerja untuk penerapan server	53
Gambar 3.18	File sumber Python yang berisi prediksi gender terjadwal.	53
Gambar 3.19	Keluaran di prompt saat memulai dari command prompt/anaconda prompt	60
Gambar 3.20	Keluaran di file log saat program dimulai	60
Gambar 3.21	Perbedaan data dari dataset lama dengan dataset baru adalah sebanyak 596 entri	63
Gambar 3.22	Pada folder klasifikasi gender terdapat proyek yang telah dikerjakan serta dataset.	65
Gambar 3.23	Laporan pengkerjaan IndoBERT yang telah dibuat sebelumnya.	66

DAFTAR KODE

Kode 3.1	Potongan kode SQL untuk pengambilan data	20
Kode 3.2	Potongan kode untuk membersihkan dataset KGGenderDataset	22
Kode 3.3	Potongan kode untuk library yang diperlukan	24
Kode 3.4	Potongan kode untuk mendefinisikan Dataset	25
Kode 3.5	Potongan kode untuk menghilangkan data yang NULL	25
Kode 3.6	Potongan kode untuk membersihkan data yang memiliki karakter khusus	26
Kode 3.7	Potongan kode untuk mengubah semua huruf jadi huruf kecil	27
Kode 3.8	Potongan kode untuk menyimpan dataset yang sudah diproses	27
Kode 3.9	Potongan kode untuk label M dan F menjadi class 1 dan 0	28
Kode 3.10	Kode ini mengubah kolom data menjadi list Python dan menyimpannya ke dalam variabel baru bernama texts dan labels.	30
Kode 3.11	Potongan kode untuk membagikan data menjadi data pelatihan	30
Kode 3.12	Potongan kode untuk mengubah kalimat jadi token dan label Laki-laki dan perempuan menjadi '1' dan '0'	31
Kode 3.13	kode def __init__ untuk class GenderDataset	32
Kode 3.14	kode def __len__ untuk class GenderDataset	33
Kode 3.15	kode def __len__ untuk class GenderDataset	33
Kode 3.16	Kode yang membantu pelabelan untuk dataset pelatihan	35
Kode 3.17	Kode untuk Eveluasi model IndoBERT	36
Kode 3.18	Kode untuk persiapan evaluasi untuk testing dataset	37
Kode 3.19	Kode untuk persiapan evaluasi untuk testing dataset	38
Kode 3.20	Kode ini untuk buat report klasifikasi	39
Kode 3.21	Kode dibuat untuk fase training untuk model	43
Kode 3.22	Argument untuk memberikan kepada model untuk training	44
Kode 3.23	Kode untuk menginisiasi Trainer	45
Kode 3.24	Kode untuk menjalankan evaluasi untuk training	46
Kode 3.25	Kode untuk menjalankan evaluasi untuk training	47
Kode 3.26	Library yang perlu di import untuk file Server	53
Kode 3.27	Import model dan tokenizer yang sudah dibuat	54
Kode 3.28	Di program python menggunakan library pyodbc sql diatas dipakai untuk ambil data langsung dari sql server	55
Kode 3.29	Preprocessing data yang didapatkan dari SQL server	55
Kode 3.30	Pembuatan fungsi prediksi di dalam program prediksi kelamin	56
Kode 3.31	pengiriman data kembali ke SQL server dengan mengirim ke store procedure	57
Kode 3.32	kode yang buat program tersebut berjalan otomatis pada jam 22.00 WIB	57
Kode 3.33	Pembuatan sistem pencatat untuk menyimpan status program prediksi kelamin	58

DAFTAR RUMUS

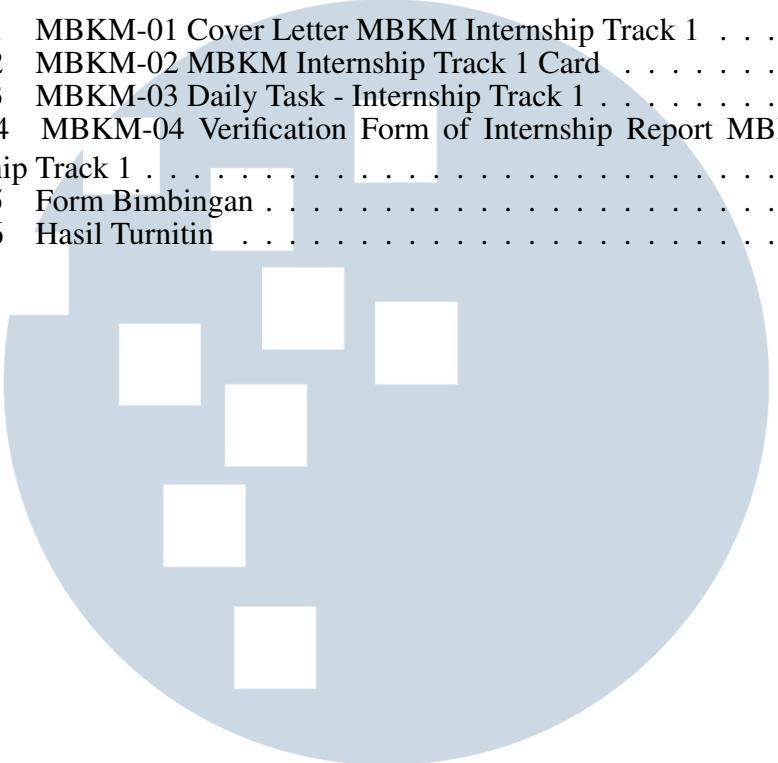
Rumus 3.1	<i>Akurasi</i>	39
Rumus 3.2	<i>Presisi untuk kelas tertentu</i>	39
Rumus 3.3	<i>Recall untuk kelas tertentu</i>	40
Rumus 3.4	<i>F1 Score untuk kelas tertentu</i>	40
Rumus 3.5	<i>Macro Average</i>	40
Rumus 3.6	<i>Weighted Average</i>	41



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA

DAFTAR LAMPIRAN

Lampiran 1	MBKM-01 Cover Letter MBKM Internship Track 1	73
Lampiran 2	MBKM-02 MBKM Internship Track 1 Card	74
Lampiran 3	MBKM-03 Daily Task - Internship Track 1	75
Lampiran 4	MBKM-04 Verification Form of Internship Report MBKM Internship Track 1	83
Lampiran 5	Form Bimbingan	84
Lampiran 6	Hasil Turnitin	85



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA