

**KLASIFIKASI BERITA HOAKS BAHASA INDONESIA
MENGUNAKAN INDOBERT *FINE-TUNING*
DENGAN PENDEKATAN *FOCAL LOSS*
PADA DATA TIDAK SEIMBANG**

THESIS

**Oleh:
AANG KUNAEFI
NIM. 210605210009**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**KLASIFIKASI BERITA HOAKS BAHASA INDONESIA
MENGUNAKAN INDOBERT *FINE-TUNING*
DENGAN PENDEKATAN *FOCAL LOSS*
PADA DATA TIDAK SEIMBANG**

THESIS

Diajukan Kepada:

**Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

Oleh:

**AANG KUNAEFI
NIM. 210605210009**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**KLASIFIKASI BERITA HOAKS BAHASA INDONESIA
MENGUNAKAN INDOBERT *FINE-TUNING*
DENGAN PENDEKATAN *FOCAL LOSS*
PADA DATA TIDAK SEIMBANG**

THESIS

Oleh:
AANG KUNAEFI
NIM. 210605210009

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 2 Juni 2025

Pembimbing I,



Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Pembimbing II,



Dr. Ririen Kusumawati, S.Si., M.Kom
NIP. 19720309 200501 2 002

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Galvo Crysdian,
NIP. 19740424 200901 1 008

**KLASIFIKASI BERITA HOAKS BAHASA INDONESIA
MENGUNAKAN INDOBERT *FINE-TUNING*
DENGAN PENDEKATAN *FOCAL LOSS*
PADA DATA TIDAK SEIMBANG**

THESIS

Oleh:
AANG KUNAEFI
NIM. 210605210009

Telah Dipertahankan di Depan Dewan Penguji Thesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Magister Komputer (M.Kom)
Tanggal: 2 Juni 2025

Susunan Dewan Penguji

Penguji I : Dr. M. Amin Hariyadi, M.T.
NIP. 19670018 200501 1 001

Penguji II : Dr. M. Imamuddin, Lc., MA.
NIP. 19740602 200901 1 010

Pembimbing I : Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Pembimbing II : Dr. Ririen Kusumawati, S.Si., M.Kom
NIP. 19720309 200501 2 002

Tanda Tangan



Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Cahyo Crysdian.
NIP. 19740424 200901 1 008

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan dibawah ini:

Nama : Aang Kunaefi
NIM : 210605210009
Program Studi : Magister Informatika
Fakultas : Sains dan Teknologi

Menyatakan dengan sebenarnya bahwa Thesis yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan, atau pikiran orang lain yang saya akui sebagai tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar Pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan Thesis ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 2 Juni 2025.

Yang membuat pernyataan



Aang Kunaefi
NIM: 210605210009

MOTTO

افضل الطرق الى الله طريقة التعليم والتعلم

Paling afdholnya jalan menuju Allah adalah dengan jalan belajar dan mengajar

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Alhamdulillah, segala puji bagi Allah *Subhanahu Wata'ala* atas karunia rohmat, taufiq dan hidayah-Nya sehingga penulis masih diberikan kesempatan untuk menyelesaikan penelitian thesis pada program studi Magister Informatika ini. Sholawat serta salam selalu penulis haturkan kepada baginda Rasulullah Muhammad *Shallallahu alaihi wasallam* atas segala perjuangannya dalam menegakkan agama islam sebagai agama *Rahmatan Lil 'Aalamin*.

Penulis menyadari bahwa dalam penyusunan thesis ini tidak terlepas dari bantuan dari berbagai pihak, oleh karena itu penulis menyampaikan terimakasih kepada:

1. Bapak Prof. Dr. H. M. Zainuddin, MA., selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Ibu Prof. Dr. Sri Harini, M.Si., selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Bapak Dr. Cahyo Crysdiyan, selaku Ketua Program Studi Magister Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Bapak Dr. Zainal Abidin, M.Kom. dan Ibu Dr. Ririen Kusumawati, S.Si., M.Kom., selaku Dosen Pembimbing yang telah meluangkan waktunya dalam memberikan bimbingan dengan penuh kesabaran.
5. Seluruh Dosen Program Studi Magister Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang yang telah memberikan ilmunya dengan penuh kesabaran.
6. Kedua orang tua tercinta, Ibunda Muntiah, Ayahanda Sutikno, yang senantiasa memberikan do'a dan restunya kepada penulis dalam menuntut ilmu.
7. Istri tercinta Azimatun Ni'mah, kedua anak tersayang Ahmad Muzakka Hunaifi dan Elma Efada Hanifa, serta adik penulis Fida Ulil Istiqomah yang selalu memberi nasihat, memotifasi, mendo'akan dan memberi semangat kepada penulis untuk menyelesaikan Thesis ini.

8. Seluruh rekan Program Studi Magister Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang yang telah memberikan saran dan kritik yang membangun dalam penulisan Thesis ini.
9. Semua pihak yang ikut membantu dalam menyelesaikan Thesis ini baik berupa materiil maupun moril.

Assalamu'alaikum Wr. Wb.

Malang, 2 Juni 2025.

Penulis.

DAFTAR ISI

HALAMAN JUDUL	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
HALAMAN PERNYATAAN	v
MOTTO	vi
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR TABEL	xi
DAFTAR GAMBAR	xii
ABSTRAK	xiii
ABSTRACT	xiv
مستخلص البحث	xv
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Pernyataan Masalah	8
1.3. Tujuan Penelitian	9
1.4. Batasan Masalah	9
1.5. Manfaat Penelitian	10
1.6. Sistematika Penulisan	10
BAB II STUDI PUSTAKA	12
2.1. Klasifikasi	12
2.2. Transformer	15
2.3. BERT dan IndoBERT	17
2.4. <i>Transfer Learning</i> dan <i>Fine Tuning</i>	18
2.5. <i>Focal Loss</i>	21
2.6. Kerangka Teori	23
2.7. Penelitian Terdahulu	26
BAB III METODOLOGI PENELITIAN	34
3.1 Tahapan Penelitian	34

3.1.1	Perencanaan	34
3.1.2	Pelaksanaan.....	38
3.1.3	Evaluasi.....	46
BAB IV METODE <i>FOCAL LOSS</i>		51
4.1.	Perhitungan.....	51
4.2.	Pengujian	52
4.3.	Analisis Hasil	56
BAB V METODE <i>CROSS ENTROPY</i>		58
5.1.	Perhitungan.....	58
5.2.	Pengujian	59
5.3.	Analisis Hasil	63
BAB VI PEMBAHASAN		65
6.1.	Analisis Kinerja IndoBERT	65
6.2.	Analisis hasil pendekatan Focal Loss.....	68
6.3.	Perbandingan kinerja model	71
BAB VII KESIMPULAN		75
7.1.	Kesimpulan.....	75
7.2.	Saran	76
REFERENSI		77

DAFTAR TABEL

Tabel 2.1 perbedaan nilai gamma	23
Tabel 2.2. Perbandingan arsitektur penelitian terdahulu.....	26
Tabel 3.1. Hasil cleaning data	37
Tabel 3.2. Encoding dataset	38
Tabel 3.3 Hasil Tokenisasi BERT.....	40
Tabel 4.1. Hasil pengujian dengan split data 70:15:15	53
Tabel 4.2. Hasil pengujian dengan split data 80:10:10	55
Tabel 5.1. Hasil pengujian dengan split data 70:15:15	60
Tabel 5.2 Hasil pengujian dengan split data 80:10:10	62
Tabel 6.1 Hasil perbandingan model <i>focal loss</i> dan <i>cross entropy</i>	72

DAFTAR GAMBAR

Gambar 2.1 Arsitektur model Transformer.....	16
Gambar 2.2 Arsitektur dasar IndoBERT.....	17
Gambar 2.3 <i>Pre-Training</i> dan <i>Fine-Tuning</i> pada IndoBERT	19
Gambar 2.4 perbandingan <i>cross entoropy</i> dengan <i>focal loss</i>	22
Gambar 2.5 Kerangka teori klasifikasi berita	24
Gambar 3.1 Tahapan penelitian	34
Gambar 3.2. Komposisi penggabungan data	35
Gambar 3.3 Tahapan <i>Pre-pocesing</i>	36
Gambar 3.4. Desain model.....	39
Gambar 3.5 Alur Proses Tokenisasi	40
Gambar 3.6. Potongan kode memanggil model dengan library transformer	41
Gambar 3.7. Confusion Matrics untuk klasifikasi berita hoaks.....	50
Gambar 4.1 Confusion matrix <i>focal loss</i> dengan split data 70:15:15	54
Gambar 4.2. Confusion matrix <i>focal loss</i> dengan split data 80:10:10.....	56
Gambar 5.1 Confusion matrix <i>cross entropy</i> dengan split data 70:15:15.....	60
Gambar 5.2. Confusion matrix <i>cross entropy</i> dengan split data 80:10:10.....	62
Gambar 6.1 Visualisasi <i>confusion metrix</i> pada perbandingan model	73

ABSTRAK

Kunaefi, Aang. 2025. **Klasifikasi Berita Hoaks Bahasa Indonesia Menggunakan IndoBERT *Fine Tuning* Dengan Pendekatan *Focal Loss* Pada Data Tidak Seimbang**. Thesis. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Zainal Abidin, M.Kom., (II) Dr. Ririen Kusumawati, S.Si., M.Kom.

Kata Kunci: Berita Hoaks, *Fine Tuning*, *Focal Loss*, IndoBERT, Pemrosesan Bahasa Alami

Penyebaran berita hoaks di media daring menjadi isu serius di tengah meningkatnya konsumsi informasi digital di kalangan masyarakat. Klasifikasi berita hoaks berbahasa Indonesia memiliki peran penting untuk menekan penyebaran informasi palsu. Salah satu tantangan utama dalam sistem klasifikasi ini adalah ketidakseimbangan distribusi data, di mana jumlah berita non-hoaks jauh lebih banyak dibandingkan berita hoaks. Penelitian ini mengusulkan pendekatan klasifikasi berita hoaks berbahasa Indonesia melalui teknologi *Natural Language Processing* (NLP) menggunakan *fine-tuning* model IndoBERT, yang merupakan *pre-trained language model* berbasis arsitektur BERT (*Bidirectional Encoder Representations from Transformers*) dan disesuaikan untuk Bahasa Indonesia. Ketidakseimbangan data diatasi menggunakan metode *Focal Loss*. Pendekatan *focal loss* dirancang untuk lebih menekankan pembelajaran pada sampel kelas minoritas yang sulit diklasifikasikan. Dataset mencakup berita Bahasa Indonesia dengan jumlah data berita hoaks jauh lebih kecil dari berita non hoaks. Hasil evaluasi menunjukkan bahwa kombinasi IndoBERT dan *Focal Loss* mampu meningkatkan performa model dengan akurasi sebesar 97.2% dibandingkan dengan pendekatan *Cross-Entropy Loss* yang mendapat akurasi 96.2%. Penelitian ini menunjukkan bahwa penggabungan model berbasis bahasa alami dengan strategi penanganan data tidak seimbang dapat memberikan hasil yang lebih akurat dalam mendeteksi berita hoaks.

ABSTRACT

Kunaefi, Aang. 2025. **The Classification of Indonesian-Language Hoax News Using IndoBERT Fine Tuning and Focal Loss Approach on Imbalanced Data**. Thesis. Magister of Informatics Faculty of Science and Technology Universitas Islam Negeri Maulana Malik Ibrahim Malang. Advisor: (I) Dr. Zainal Abidin, M.Kom., (II) Dr. Ririen Kusumawati, S.Si., M.Kom.

Keywords: Hoax News, *Fine Tuning*, *Focal Loss*, IndoBERT, *Natural Language Processing*

The spread of hoax news on online media is becoming a serious issue amidst society's increasing digital information consumption. The classification of Indonesian-language hoax news plays an important role in decreasing the spread of fake information. One main challenge in the classification system is the imbalanced data distribution, in which the number of factual news is significantly higher than hoax ones. The research proposes an Indonesian-language hoax news classification approach using *Natural Language Processing* (NLP) technology of *fine-tuning* IndoBERT model, a *pre-trained* language model based on BERT (*Bidirectional Encoder Representations from Transformers*), which is adjusted for the Indonesian language. The imbalanced data can be solved using the *Focal Loss* method. It is designed to emphasize learning on minority class samples, which are hard to classify. The dataset consisting of Indonesian-language news shows that the number of hoax news is significantly fewer than the factual news. The evaluation result shows that the combination of IndoBERT and *Focal Loss* can improve the model performance with an accuracy of 97.2% compared to the *Cross-Entropy Loss* approach with an accuracy of 96.2%. The research shows that the model combination based on natural language with the strategy to deal with imbalanced data can provide a more accurate result in detecting hoax news

 <p>Translator  Rizka Yantuarti NIPPPK 197801242023212005</p>	<p>Date 16-6-2025</p>
---	---------------------------

مستخلص البحث

حنيفي، أنج. 2025. تصنيف الأخبار الكاذبة باللغة الإندونيسية باستخدام تمثيل التشفير ثنائي الاتجاه من المحول الإندونيسي (IndoBERT) بالضبط الدقيق مع مدخل الفقدان المركزي (*Focal Loss*) على بيانات غير متوازنة. رسالة الماجستير. قسم المعلومات كلية علوم العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: د. زين العابدين، الماجستير؛ المشرف الثاني: د. ريرين كوسوما واتي، الماجستير.

الكلمات الرئيسية: أخبار كاذبة، ضبط دقيق، فقدان مركزي، إندوبيرت، معالجة اللغة الطبيعية.

أصبح انتشار الأخبار الكاذبة عبر وسائل الإعلام الرقمية قضية خطيرة في ظل تزايد استهلاك المعلومات الرقمية بين المجتمع. تصنيف الأخبار الكاذبة باللغة الإندونيسية يلعب دورًا مهمًا في تقليل انتشار المعلومات المزيفة. من أكبر التحديات في نظام التصنيف هذا هي عدم توازن توزيع البيانات، حيث أن عدد الأخبار غير الكاذبة أكثر بكثير مقارنةً بالأخبار الكاذبة. اقترحت هذه الرسالة مدخلا لتصنيف الأخبار الكاذبة باللغة الإندونيسية من خلال تقنية معالجة اللغة الطبيعية (NLP) باستخدام تقنية الضبط الدقيق لنموذج IndoBERT، وهو نموذج اللغة مسبق التدريب على أساس بنية BERT (تمثيل التشفير ثنائي الاتجاه من المحولات) والذي تم ضبطه للغة الإندونيسية. يتم معالجة عدم توازن البيانات باستخدام طريقة الفقدان المركزي (*Focal Loss*). تم تصميم هذه الطريقة لزيادة التركيز على التعليم من عينات الفئة الأقلية التي يصعب تصنيفها. شملت مجموعة البيانات أخبارًا باللغة الإندونيسية مع عدد أكبر بكثير من الأخبار الحقيقية مقارنةً بالأخبار الكاذبة. أظهرت نتائج التقييم أن الجمع بين IndoBERT و *Focal Loss* قادر على تحسين أداء النموذج بدقة بلغت 97.2% مقارنةً بطريقة الفقدان الانتروبيا المتقاطع التي حصلت على دقة بنسبة 96.2%. أشارت هذه النتيجة إلى أن دمج النموذج الذي يعتمد على معالجة اللغة الطبيعية مع استراتيجية التعامل مع البيانات غير المتوازنة يمكن تحقيق نتائج أكثر دقة في كشف الأخبار الكاذبة.

Penerjemah  M. Mubasysir NIPPPK: 198605132014041001	Tanggal 10-06-25
---	---------------------



BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Seiring kemajuan teknologi informasi, media daring telah menjadi sarana utama dalam penyebaran informasi, menggantikan dominasi media cetak yang sebelumnya lebih umum digunakan. Pada tahun 2021, terjadi peningkatan signifikan dalam jumlah masyarakat Indonesia yang memiliki akses terhadap internet, di mana jumlah pengguna meningkat dari 175 juta menjadi 202 juta orang (Juarto & Yulianto, 2023). Berdasarkan laporan yang dirilis oleh We Are Social dan Meltwater, pada Januari 2024 jumlah pengguna internet di Indonesia tercatat mencapai 212,9 juta atau sekitar 77% dari total populasi. Dari angka tersebut, sebanyak 167 juta orang (60,4% dari populasi) merupakan pengguna aktif media sosial. Perkembangan ini menunjukkan bahwa masyarakat Indonesia semakin terintegrasi dengan ekosistem digital dalam kehidupan sehari-hari, termasuk dalam memperoleh dan menyebarkan informasi.

Kemudahan akses terhadap informasi melalui media daring juga membawa tantangan tersendiri. Informasi yang beredar secara luas di dunia maya sering kali tidak melalui proses verifikasi atau penyaringan yang ketat sebagaimana yang lazim ditemukan dalam media konvensional. Tidak adanya mekanisme editorial yang memadai serta keterbukaan platform digital menyebabkan siapa pun dapat menjadi produsen sekaligus distributor informasi. Akibatnya, berbagai bentuk informasi

yang tidak valid atau menyesatkan, termasuk berita hoaks, dapat tersebar dengan sangat cepat dan luas di masyarakat. Fenomena ini diperkuat oleh penelitian yang dilakukan oleh Vosoughi dkk. (2018), yang menunjukkan bahwa informasi palsu memiliki kecenderungan untuk menyebar lebih cepat dibandingkan dengan informasi yang benar.

Tujuan utama dari media daring adalah untuk menyampaikan informasi secara cepat, mudah diakses, dan relevan dengan kebutuhan masyarakat. Namun, kecepatan penyebaran informasi tersebut sering kali tidak diimbangi dengan akurasi dan kebenaran isi berita. Oleh karena itu, masyarakat perlu dibekali dengan literasi digital yang memadai agar mampu memilah informasi yang dapat dipercaya. Selain itu, pihak-pihak yang terlibat dalam penyebaran informasi, baik individu maupun institusi media, memiliki tanggung jawab untuk memastikan bahwa informasi yang disampaikan telah melalui proses verifikasi agar tidak menyesatkan publik dan tidak menimbulkan keresahan sosial. Dalam Al-Qur'an Allah berfirman.

وَلَا تَلْبِسُوا الْحَقَّ بِالْبَاطِلِ وَتَكْتُمُوا الْحَقَّ وَأَنْتُمْ تَعْلَمُونَ - البقرة - ٤٢

Artinya: *Dan janganlah kamu campuradukkan kebenaran dengan kebatilan dan (janganlah) kamu sembunyikan kebenaran, sedangkan kamu mengetahuinya (QS : Al-Baqoroh : 42)*

Dalam terjemahan Tafsir Ibnu Katsir dijelaskan bahwa Allah melarang orang-orang yahudi dari kesengajaan mereka mencampuradukkan antara kebenaran dan kebatilan, serta tindakan mereka menyembunyikan kebenaran dan menampakkan kebatilan (Ibnu Katsir, 2003, hlm 114). Ayat tersebut mengandung pesan yang menegaskan pentingnya membedakan antara informasi yang benar (non-hoaks) dan informasi yang menyesatkan (hoaks). Berita hoaks merupakan

bentuk informasi yang sengaja dibuat untuk menyesatkan, membingungkan, atau memanipulasi opini publik. Dalam konteks lain, hoaks juga dapat dipahami sebagai upaya untuk mengaburkan kebenaran melalui penyebaran pesan-pesan keliru secara masif, sehingga pesan yang benar menjadi tertutupi (Gumilar dkk., 2017). Berdasarkan laporan yang dirilis oleh Komite Litbang MAFINDO (Masyarakat Anti Fitnah Indonesia), pada semester pertama tahun 2024 ditemukan sebanyak 2.119 kasus berita hoaks. Temuan ini menunjukkan bahwa penyebaran hoaks masih menjadi permasalahan serius di Indonesia. Terdapat beberapa saluran utama yang digunakan dalam distribusi informasi palsu tersebut, dengan lima platform terbesar yaitu Facebook (30,4%), YouTube (21,8%), TikTok (16,9%), Twitter (15,2%), dan WhatsApp (7,4%). Upaya untuk melawan penyebaran hoaks menjadi sangat penting dalam rangka menjaga integritas informasi, stabilitas sosial, serta membangun dan mempertahankan kepercayaan publik terhadap media dan institusi informasi.. Dalam Al-Qur'an Allah berfirman:

يَا أَيُّهَا الَّذِينَ آمَنُوا إِنْ جَاءَكُمْ فَاسِقٌ بِنَبَأٍ فَتَبَيَّنُوا أَنْ تُصِيبُوا قَوْمًا بِجَهَالَةٍ فَتُصْبِحُوا
عَلَىٰ مَا فَعَلْتُمْ نَادِمِينَ - الحجرات - ٦

Artinya: *Wahai orang-orang yang beriman, jika seorang fasik datang kepadamu membawa berita penting, maka telitilah kebenarannya agar kamu tidak mencelakakan suatu kaum karena ketidaktahuan(-mu) yang berakibat kamu menyesali perbuatanmu itu. (QS – Al-Hujurot :6)*

Dalam terjemahan Tafsir Ibnu Katsir dijelaskan Allah *Subhanahu Wata'ala* memerintahkan agar benar-benar meneliti berita yang dibawa oleh orang-orang fasik dalam rangka mewaspadainya, sehingga tidak ada seorangpun yang memberikan keputusan berdasarkan perkataan orang fasik tersebut, di mana pada saat itu orang fasik tersebut berpredikat sebagai orang pendusta dan berbuat

kekeliruan, sehingga orang yang memberikan keputusan berdasarkan ucapan orang fasik itu berarti ia telah mengikutinya dari belakang (Ibnu Katsir, 2004, hlm 476).

Ayat tersebut mengandung perintah dari Allah agar setiap individu bersikap kritis dan berhati-hati dalam menerima serta menyikapi informasi yang diterima. Sebelum sebuah informasi disebarkan kepada pihak lain, sangat penting untuk terlebih dahulu melakukan verifikasi terhadap kebenarannya. Tindakan ini merupakan salah satu bentuk tanggung jawab moral sekaligus langkah yang baik dalam mencegah penyebaran informasi hoaks. Penyebaran informasi tanpa melalui proses klarifikasi tidak hanya berpotensi menimbulkan kesalahpahaman, tetapi juga dapat menciptakan keresahan di tengah masyarakat. Oleh karena itu, sikap selektif dan teliti dalam menyaring informasi menjadi bagian penting dari upaya membangun ekosistem komunikasi yang sehat, jujur, dan dapat dipercaya, baik dalam konteks sosial maupun dalam ruang digital yang terbuka. Langkah tersebut sesuai dengan sabda *Rasulullah Shallallahu ‘Alaihi Wasallam* diriwayatkan dari Abu Hurairah *Radhiyallahu‘anhu* bahwa *Rasulullah Shallallahu ‘alaihi wasallam* bersabda:

عن ابو هريرة رضي الله عنه, قال رسول الله صلى الله عليه وسلم: إِنَّ اللَّهَ يَرْضَى لَكُمْ ثَلَاثًا وَيَكْرَهُ لَكُمْ ثَلَاثًا فَيَرْضَى لَكُمْ أَنْ تَعْبُدُوهُ وَلَا تُشْرِكُوا بِهِ شَيْئًا وَأَنْ تَعْتَصِمُوا بِحَبْلِ اللَّهِ جَمِيعًا وَلَا تَفَرَّقُوا وَيَكْرَهُ لَكُمْ قِيلَ وَقَالَ وَكَثْرَةَ السُّؤَالِ وَإِضَاعَةَ الْمَالِ

Artinya : *Sesungguhnya Allah meridhai tiga hal dan membenci tiga hal bagi kalian. Dia meridhai kalian untuk menyembah-Nya, dan tidak menyekutukan sesuatu pun dengan-Nya, serta berpegang teguhlah kalian dengan tali Allah dan tidak berpecah belah. Dia pun membenci tiga hal bagi kalian, menceritakan sesuatu yang tidak jelas sumbernya, banyak bertanya, dan membuang-buang harta. (HR. Muslim no. 1715)*

Hadis tersebut memberikan peringatan yang kuat agar setiap individu berhati-hati dalam menyampaikan suatu informasi, khususnya apabila informasi tersebut belum jelas asal-usul atau kebenarannya. Dalam Islam, menyampaikan berita yang belum terverifikasi tidak hanya dianggap sebagai tindakan ceroboh, tetapi juga berpotensi menimbulkan fitnah atau kesalahpahaman yang merugikan pihak lain. Prinsip kehati-hatian ini menjadi semakin relevan di era digital saat ini, di mana arus informasi bergerak sangat cepat dan siapa pun dapat dengan mudah menjadi penyebar berita melalui berbagai platform media sosial. Oleh karena itu, hadis ini mengajarkan nilai tanggung jawab dalam berkomunikasi, sekaligus menjadi dasar etis untuk menolak budaya menyebarkan informasi tanpa verifikasi. Dalam konteks modern, pesan ini dapat dimaknai sebagai ajakan untuk menerapkan literasi digital dan berpikir kritis sebelum membagikan konten apa pun, demi mencegah tersebarnya hoaks dan menjaga integritas informasi dalam masyarakat..

Salah satu pendekatan untuk membedakan antara berita hoaks dan berita non-hoaks, serta untuk mencegah penyebaran informasi secara sembarangan, adalah melalui proses klasifikasi berita. Proses ini bertujuan untuk membantu masyarakat dalam membedakan dengan jelas antara berita non-hoaks dan berita hoaks. Dengan demikian, masyarakat dapat lebih berhati-hati dan tidak mudah terpengaruh untuk mempercayai serta menyebarkan informasi yang belum terverifikasi kebenarannya, agar tidak menimbulkan kesalahpahaman di tengah masyarakat serta mencegah tersebarnya informasi yang bersifat menyesatkan.

Dalam melakukan klasifikasi berita hoaks terdapat beberapa tantangan yang harus diatasi, salah satunya pada kompleksitas linguistik. Berita hoaks sering kali

menyerupai berita non-hoaks dalam struktur dan gaya bahasa, serta cenderung menggunakan diksi yang emosional atau manipulatif, sehingga mempersulit proses klasifikasi. Model berbasis *transformer* seperti IndoBERT memiliki kemampuan representasi semantic secara menyeluruh, mendalam dan kontekstual, menjadikannya lebih unggul dalam menangani kompleksitas ini. Pendekatan ini digunakan sebagai respons terhadap keterbatasan metode klasik. Algoritma seperti *Naive Bayes* dan SVM yang mengandalkan representasi teks yang dangkal dan tidak kontekstual, sehingga kurang efektif dalam menangkap makna yang tergantung pada struktur kalimat (Altinel & Ganiz, 2018). Arsitektur CNN-LSTM memang menawarkan kemampuan yang lebih baik dalam mengenali urutan dan fitur lokal dan global dalam teks, namun tetap terbatas dalam memahami konteks semantik secara menyeluruh, terutama dalam teks dengan struktur kompleks (Lidkk., 2020). Evaluasi empiris menunjukkan bahwa IndoBERT mampu memberikan performa yang lebih konsisten dalam memahami struktur dan makna dalam bahasa Indonesia. Namun performa model ini tetap menurun saat dihadapkan pada distribusi kelas yang tidak seimbang.

Studi yang dilakukan oleh Tobing dkk. (2025), yang memanfaatkan *fine-tuning* IndoBERT untuk mendeteksi hoaks politik, data terdiri dari 20.928 berita faktual dan 2.251 hoaks, pada penelitian ini masalah ketimpangan ini diatasi dengan teknik *undersampling*. Teknik *undersampling* bertujuan menyeimbangkan jumlah data antar kelas dengan mengurangi jumlah sampel dari kelas mayoritas, hal tersebut dapat membuat hilangnya informasi penting karena menghapus sebagian besar data dari kelas mayoritas. Sementara itu, penelitian yang dilakukan oleh

Ridho & Yulianti (2024) membandingkan IndoBERT dengan model lain seperti CNN-LSTM dan *Naive Bayes* pada dataset yang tidak seimbang, untuk mengatasi ketidakseimbangan data digunakan teknik *oversampling* SMOTE. Penelitian ini berhasil meningkatkan akurasi model dari 92% menjadi 98%. SMOTE adalah teknik *oversampling* yang berfungsi untuk menyeimbangkan dataset tidak seimbang dengan menambahkan data sintetis (bukan menduplikasi data minoritas). SMOTE bisa efektif untuk menyeimbangkan data numerik sederhana, tapi kurang cocok untuk data teks. Selain itu *oversampling* SMOTE juga beresiko *overfitting* jika data minoritas sedikit dan tidak representative (Buda dkk., 2018).

Ketidakseimbangan data antara berita hoaks dan non-hoaks menjadi masalah yang harus diselesaikan untuk mendapatkan hasil prediksi yang akurat, seperti dalam penelitian ini jumlah data hoaks sebanyak 738, sedangkan jumlah data non-hoaks sebanyak 2.957, jumlah tersebut sangat tidak seimbang sehingga diperlukan pendekatan khusus untuk menangani ketidakseimbangan data tersebut. Untuk menangani keterbatasan pada penelitian sebelumnya dalam menangani data tidak seimbang, dalam penelitian ini diterapkan model *focal loss* untuk memfokuskan pembelajaran pada sampel yang sulit pada kelas minoritas (hoaks), sehingga meningkatkan sensitivitas model terhadap berita hoaks. pendekatan *focal loss* dipilih karena tidak memerlukan modifikasi data seperti yang dilakukan oleh metode *oversampling* maupun *undersampling*. Teknik *oversampling* berisiko menyebabkan *overfitting* karena menambah data sintetis pada kelas minoritas (Buda dkk., 2018), sementara *undersampling* berpotensi mengurangi informasi penting dari kelas mayoritas (C. J. Lin dkk., 2009). *Focal Loss* menawarkan solusi

yang lebih efisien dengan menangani ketidakseimbangan data tanpa mengubah distribusi data asli, sehingga model tetap dapat belajar dari keseluruhan data yang tersedia secara utuh. *Focal Loss* bekerja langsung pada fungsi *loss* dengan menurunkan bobot contoh yang mudah diprediksi dan memperbesar kontribusi dari contoh sulit, sehingga menjaga keseimbangan pembelajaran tanpa memodifikasi distribusi data. Berbeda dengan *cross-entropy loss* yang memperlakukan semua contoh secara setara dan cenderung bias terhadap kelas mayoritas, *Focal Loss* lebih adaptif dalam menangani distribusi tidak seimbang. IndoBERT, sebagai model berbasis *Transformer* yang dilatih khusus untuk Bahasa Indonesia, unggul dalam memahami konteks dua arah dan relasi semantik antarkata. Didukung oleh pendekatan *transfer learning*, IndoBERT memungkinkan adaptasi efisien dan akurat dalam tugas klasifikasi hoaks. Oleh sebab itu, kombinasi IndoBERT dengan *focal loss* dipandang sebagai pendekatan yang lebih efektif dalam menangani tantangan klasifikasi berita hoaks, baik dari sisi representasi linguistik maupun dari sisi distribusi data yang tidak seimbang.

1.2. Pernyataan Masalah

Pernyataan masalah dalam penelitian ini adalah:

- a. Bagaimana performa model IndoBERT dalam mengklasifikasikan berita hoaks berbahasa Indonesia setelah dilakukan *fine-tuning* pada dataset yang tidak seimbang?
- b. Apakah penerapan *focal loss* dapat meningkatkan performa model, khususnya dalam mendeteksi berita dari kelas minoritas (hoaks)?

- c. Bagaimana perbandingan performa model IndoBERT yang dilatih menggunakan *focal loss* dibandingkan dengan *cross entropy loss* dalam klasifikasi berita hoaks?

1.3. Tujuan Penelitian

Berdasarkan pernyataan masalah yang telah disebutkan sebelumnya, tujuan yang ingin dicapai dalam penelitian ini adalah:

- a. Mengetahui performa yang dihasilkan dari *fine-tuning* model IndoBERT dalam mengklasifikasi berita hoaks berbahasa Indonesia pada dataset tidak seimbang.
- b. Menerapkan dan menguji efektivitas *focal loss* dalam pelatihan model IndoBERT untuk meningkatkan performa model khususnya dalam mendeteksi berita dari kelas minoritas (hoaks)
- c. Membandingkan performa model IndoBERT yang dilatih menggunakan *focal loss* dengan model yang dilatih menggunakan *cross entropy loss* berdasarkan metrik evaluasi seperti akurasi, *precision*, *recall*, dan *f1-score*.

1.4. Batasan Masalah

Batasan-batasan yang digunakan dalam penelitian ini antara lain:

- a. Dataset yang digunakan dalam penelitian ini merupakan kumpulan berita berbahasa Indonesia yang sudah memiliki label hoaks dan non-hoaks yang tersedia secara publik melalui platform Kaggle, Huggingface, dan Mendeley.
- b. Analisis klasifikasi dibatasi pada teks berita, tanpa memasukkan komponen lain seperti judul, gambar atau video.

1.5. Manfaat Penelitian

Mengklasifikasikan berita palsu / hoaks diharapkan dapat;

- a. Mengurangi kerugian social, ekonomi dan psikologi akibat penyebaran berita hoaks
- b. Mencegah manipulasi opini public melalui informasi berita hoaks
- c. Meningkatkan transparansi dan kepercayaan terhadap informasi yang beredar di ruang public.
- d. Membantu masyarakat untuk memilih informasi yang bisa dipercaya (fakta) dan tidak dapat dipercaya (hoaks), sehingga masyarakat dapat berpegang teguh pada kebiasaan berkata benar.

1.6. Sistematika Penulisan

Sistematika penulisan yang digunakan dalam penelitian ini adalah sebagai berikut:

BAB I PENDAHULUAN

Bab pendahuluan menjelaskan tentang latar belakang masalah, pernyataan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, dan sistematika penulisan dalam penelitian.

BAB II STUDI PUSTAKA

Bab studi pustaka memuat teori-teori dan karya ilmiah terdahulu yang berkaitan dengan penelitian yang bersumber dari beberapa referensi yang valid.

BAB III METODOLOGI PENELITIAN

Bab metodologi penelitian memuat tentang tahapan-tahapan yang digunakan dalam penelitian mulai dari tahap pengumpulan data sampai tahap evaluasi

BAB IV METODE FOCAL LOSS

Bab ini membahas tentang implementasi *fine tuning* IndoBERT yang menggunakan *focal loss* untuk mengatasi data tidak seimbang

BAB V METODE CROSS ENTROPY

Bab ini membahas tentang implementasi *fine tuning* indoBERT yang menggunakan *Cross Entropy* untuk mengatasi data tidak seimbang sebagai perbandingan dari metode *focal loss*

BAB VI PEMBAHASAN

Bab pembahasan memuat tentang pembahasan hasil penelitian dan menyampaikan integrasi dan analogi penelitian dengan nilai-nilai Islam

BAB VII KESIMPULAN

Bab kesimpulan merupakan bab terakhir yang berisi kesimpulan dari hasil penelitian dan memberikan saran dari penulis untuk penelitian selanjutnya.

BAB II

STUDI PUSTAKA

2.1. Klasifikasi

Klasifikasi adalah suatu metode sistematis yang digunakan untuk mengelompokkan data atau objek berdasarkan kemiripan atribut, dengan tujuan menyederhanakan informasi yang kompleks serta mendukung proses analisis dan pengambilan keputusan (Bardab dkk., 2021). Pendekatan ini telah banyak digunakan di berbagai disiplin ilmu, termasuk dalam bidang teknologi informasi, terutama sebagai fondasi untuk sistem prediktif dan otomatisasi data. Proses klasifikasi melibatkan pengenalan pola dari data pelatihan guna menetapkan data ke dalam kategori atau label yang telah ditentukan sebelumnya (Oad dkk., 2024).

Klasifikasi dalam konteks *machine learning* termasuk dalam *supervised learning*, di mana model dilatih menggunakan data berlabel untuk mengenali pola dan membuat prediksi terhadap data baru yang belum pernah dilihat sebelumnya (Aggarwal dkk., 2020). Pendekatan ini banyak digunakan dalam berbagai aplikasi, seperti deteksi spam (Almeida dkk., 2011) klasifikasi sentimen (Medhat dkk., 2014), dan deteksi berita hoaks (Kaliyar dkk., 2021). Tujuan utama klasifikasi adalah meminimalkan kesalahan prediksi dan mengoptimalkan akurasi dengan memahami hubungan antara fitur dalam data (Pudjihartono dkk., 2022). Proses klasifikasi melibatkan beberapa tahapan penting, termasuk pengumpulan data, pembersihan data (*data cleaning*), pembagian data (*data splitting*), pelatihan model penelitian, dan evaluasi hasil penelitian.

a. Pengumpulan Data

Pengumpulan data adalah tahap awal dalam proses klasifikasi. Data dapat berasal dari berbagai sumber, termasuk data primer dan data sekunder. Data primer ikumpulkan secara langsung dari responden atau objek penelitian melalui metode seperti wawancara, survei, atau observasi (Pramiyati, 2017). Sementara itu, data sekunder adalah data yang diperoleh atau dikumpulkan dari sumber-sumber yang sudah ada seperti laporan atau artikel terdahulu (Abidin & Wiyono, 2017). Dalam penelitian klasifikasi berita hoaks, data sekunder sering digunakan karena lebih mudah diakses dan biasanya telah terstruktur dengan baik.

b. Pembersihan Data

Pembersihan data adalah langkah penting untuk memastikan kualitas dan konsistensi dataset sebelum digunakan dalam pelatihan model. Data yang tidak lengkap, tidak akurat, atau tidak relevan dapat mengganggu proses pelatihan dan mengurangi akurasi prediksi (Wu, 2013). Proses ini meliputi penghapusan data duplikat, penyesuaian format teks, normalisasi, serta penghilangan karakter khusus (Geni dkk., 2023). Untuk teks, pembersihan data dapat mencakup penghapusan *stopwords*, tanda baca, dan normalisasi kata untuk mengurangi noise dalam data dan meningkatkan kinerja model NLP. Data yang bersih akan membantu model untuk lebih fokus, sehingga menghasilkan prediksi yang lebih akurat.

c. Pembagian Data

Pembagian data atau *data splitting* merupakan langkah penting dalam pengembangan model *machine learning* yang berfungsi untuk memastikan model

dapat dilatih, divalidasi, dan diuji dengan optimal. Model IndoBERT membutuhkan tiga set data, yaitu data pelatihan (*training data*), data validasi (*validation data*), dan data pengujian (*test data*) (Yang dkk., 2020). Berbeda dengan model klasik seperti *Regresi Logistik* dan *Decision Tree* yang umumnya hanya membagi data menjadi dua (*training* dan *testing*), model berbasis BERT memerlukan tiga set data. Pembagian ini penting karena model BERT memiliki struktur yang sangat fleksibel dan kompleks, sehingga rentan terhadap *overfitting* jika tidak divalidasi dengan baik. Data pelatihan digunakan untuk mengenalkan pola dalam data kepada model, sedangkan data validasi berfungsi untuk menyesuaikan parameter model serta mengurangi risiko *overfitting* selama proses pelatihan (Rahmawati dkk., 2022). Sementara itu, data pengujian digunakan untuk mengukur performa model pada data baru yang belum pernah dilihat sebelumnya, sehingga hasil pengujian lebih mencerminkan kinerja model dalam situasi nyata (Hu dkk., 2022).

d. Pelatihan Model

Pelatihan model adalah proses di mana model klasifikasi belajar dari data pelatihan untuk mengenali pola dan hubungan antar fitur dalam data. Model akan mencoba meminimalkan kesalahan prediksi dengan menyesuaikan bobot selama proses pelatihan (Modanwal & Sarawadekar, 2016). Berbagai algoritma seperti *Decision Tree*, *SVM*, *Naive Bayes*, dan BERT dapat digunakan tergantung pada kompleksitas data dan tujuan klasifikasi. Untuk model berbasis transformer seperti BERT, pelatihan melibatkan *fine-tuning* pada data spesifik untuk meningkatkan akurasi prediksi (Devlin dkk., 2018). Model yang baik harus mampu

menggeneralisasi pola dari data pelatihan ke data yang belum pernah dilihat sebelumnya, bukan hanya menghafal pola yang ada.

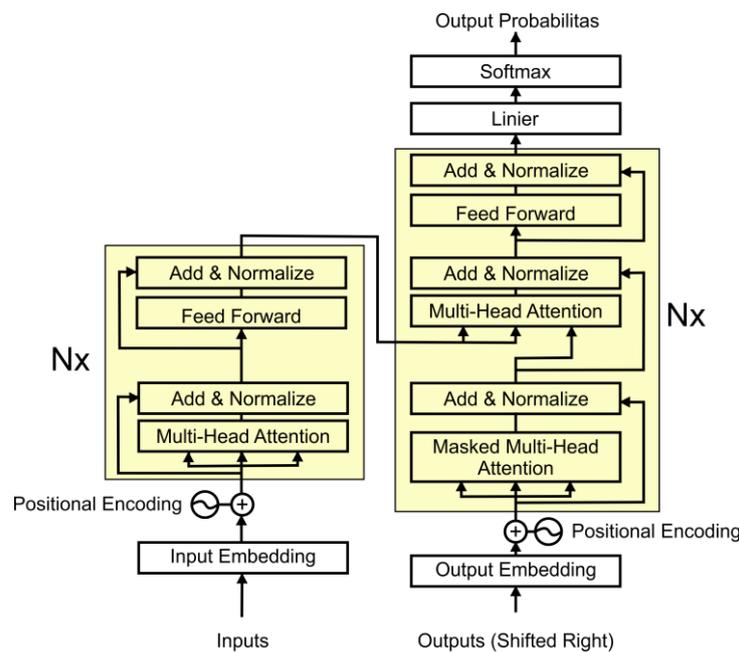
e. Evaluasi Model

Evaluasi model adalah tahap akhir dalam proses klasifikasi untuk menilai seberapa baik model dalam mengenali pola yang diharapkan. Metrik evaluasi yang umum digunakan meliputi akurasi, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Evaluasi yang tepat sangat penting untuk memastikan model tidak hanya menghafal data pelatihan, tetapi juga dapat menggeneralisasi ke data baru. Metrik seperti *F1-score* dan *recall* sering dianggap lebih penting daripada akurasi, karena fokusnya pada deteksi kelas minoritas yang lebih sulit dikenali (Kaliyar dkk., 2021).

2.2. Transformer

Transformer adalah arsitektur *deep learning* yang dikembangkan berdasarkan mekanisme *multi-head attention* (Vaswani dkk., 2017). Teks diubah menjadi representasi numerik yang disebut token, kemudian token-token ini direpresentasikan sebagai vektor melalui pencarian dari *word embedding*. Arsitektur ini terdiri atas dua komponen utama, yaitu *encoder* dan *decoder*, yang masing-masing terdiri dari enam lapisan identik. Setiap lapisan mencakup *multi-head attention*, *feed-forward neural network*, *residual connection*, dan *layer normalization*. Dalam konteks penerjemahan, *encoder* menghasilkan representasi kontekstual dari kalimat sumber (misalnya dalam bahasa Inggris), sedangkan *decoder* memanfaatkan representasi tersebut untuk menghasilkan terjemahan ke

dalam bahasa target. Dengan kata lain, *encoder* mempelajari konteks dari kalimat, dan *decoder* menerjemahkannya ke bahasa lain. Baik *encoder* maupun *decoder* berupaya memahami bahasa, menjadikan model Transformer unggul dalam berbagai aplikasi linguistik (Isa dkk., 2022). Arsitektur dasar model *Transformer* yang terdiri dari *encoder* dan *decoder* dapat dilihat pada gambar 2.1.



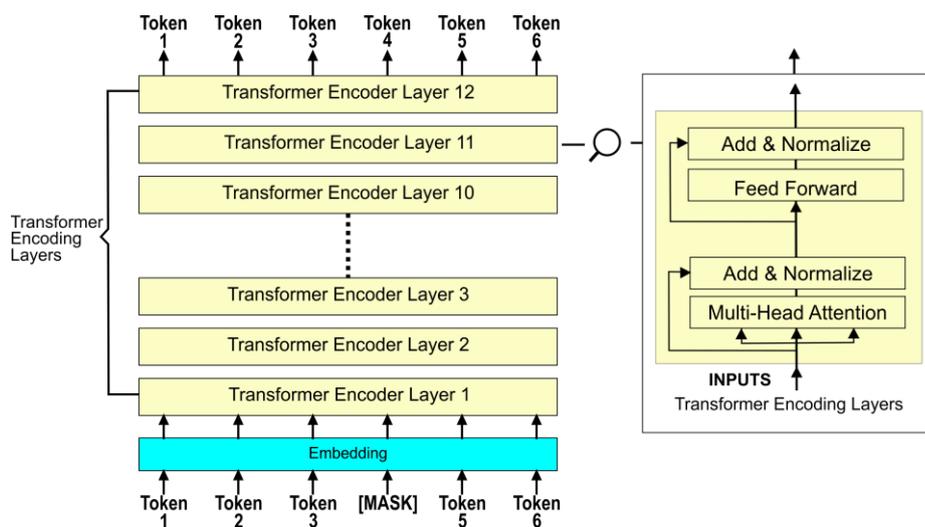
Gambar 2.1 Arsitektur model *Transformer*
Sumber: diolah dari Vaswani dkk. (2017)

Berbeda dengan model sebelumnya seperti *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM), *Transformer* menghilangkan ketergantungan terhadap pemrosesan sekuensial dan menggantikannya dengan pendekatan berbasis *self-attention*. Mekanisme ini memungkinkan model memperhatikan seluruh bagian dari input secara simultan, sehingga efisien dalam menangkap relasi semantik jangka panjang. Untuk mempertahankan informasi posisi, *Transformer* menambahkan *positional encoding* karena tidak memproses data secara berurutan.

2.3. BERT dan IndoBERT

BERT (*Bidirectional Encoder Representations from Transformers*) merupakan model representasi bahasa berbasis arsitektur. BERT memanfaatkan pendekatan dua arah (*bidirectional*) dalam memproses teks, memungkinkan pemahaman konteks kata secara simultan dari kiri ke kanan dan sebaliknya. Hal ini berbeda dengan pendekatan *left to right* atau *right to left* pada model sebelumnya yang cenderung kehilangan konteks penuh. Untuk mencapai hal ini, BERT dilatih melalui dua mekanisme utama yaitu *Masked Language Modeling* (MLM) dan *Next Sentence Prediction* (NSP).

Pada tugas MLM, sebagian token dalam kalimat secara acak disembunyikan (*masked*), dan model diminta untuk memprediksi token yang hilang berdasarkan konteks di sekitarnya. Sedangkan pada NSP, model dilatih untuk menilai apakah dua kalimat diberikan secara berurutan dalam teks asli. Kombinasi dua strategi ini memungkinkan BERT membentuk representasi bahasa yang kontekstual, fleksibel, dan generalis untuk berbagai aplikasi NLP.



Gambar 2.2 Arsitektur dasar IndoBERT
Sumber: diolah dari Noorian dkk. (2024)

Keberhasilan BERT dalam banyak tugas NLP mendorong pengembangannya ke berbagai bahasa, termasuk bahasa Indonesia. IndoBERT adalah model turunan BERT yang dilatih menggunakan Indo4B *Corpus*, sebuah himpunan data besar berisi sekitar empat miliar kata dari berbagai sumber teks berbahasa Indonesia (Isa dkk., 2022). Sumber-sumber tersebut meliputi berita online, media sosial, artikel ilmiah populer, Wikipedia, hingga subtitle video, yang memberikan keragaman gaya bahasa dari formal hingga kasual.

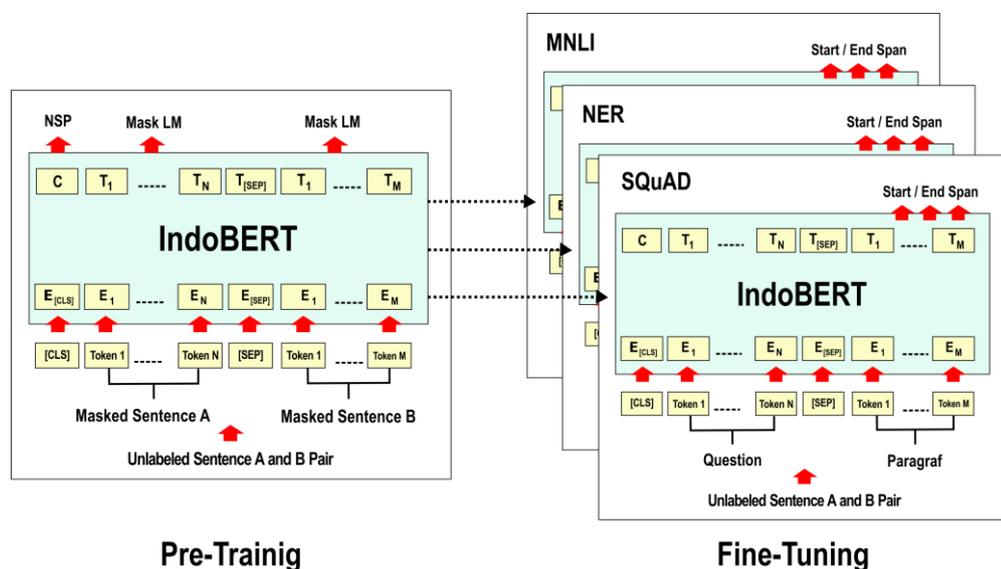
Secara arsitektural, ditunjukkan pada gambar 2.2, Model BERT hanya menggunakan bagian *encoder* dan tidak menggunakan bagian dari *decoder* dari *transformer*. IndoBERT mempertahankan struktur *encoder* BERT dengan konfigurasi model seperti IndoBERTBASE, yang terdiri atas 12 lapisan *encoder*, 12 *self-attention heads*, dan dimensi *hidden size* sebesar 768. Model ini memiliki total sekitar 124,5 juta parameter. Tersedia juga varian lain seperti IndoBERTLARGE dan versi ringan IndoBERT-lite, dengan variasi kompleksitas yang disesuaikan dengan kebutuhan dan sumber daya komputasi. Keberadaan IndoBERT memungkinkan pengembangan sistem NLP dalam bahasa Indonesia yang lebih akurat dan relevan terhadap konteks lokal.

2.4. Transfer Learning dan Fine Tuning

Transfer learning adalah pendekatan dalam pembelajaran mesin di mana pengetahuan yang telah diperoleh dari suatu tugas pelatihan digunakan kembali untuk menyelesaikan tugas lain yang berbeda namun masih memiliki kesamaan karakteristik (Pan & Yang, 2010). Dalam konteks pemrosesan bahasa alami, transfer learning umumnya dilakukan dengan melatih model besar seperti BERT

pada korpus teks berskala besar secara tidak terawasi, kemudian mengadaptasi parameter model tersebut untuk menyelesaikan tugas-tugas spesifik melalui proses *fine-tuning*. Pendekatan ini memungkinkan pemanfaatan representasi bahasa yang telah dipelajari sebelumnya tanpa harus melatih model dari awal, sehingga menghemat sumber daya dan waktu pelatihan secara signifikan.

BERT dan IndoBERT menggunakan dua tahap utama dalam proses pembelajarannya: *pre-training* dan *fine-tuning*. Tahap *pre-training* dilakukan dengan data tanpa label menggunakan dua tugas prediktif, yaitu MLM dan NSP. Hasil dari tahap ini adalah model yang telah membentuk pemahaman umum terhadap struktur dan semantik bahasa. Setelahnya, pada tahap *fine-tuning*, model yang telah terlatih tersebut disesuaikan dengan data berlabel dari tugas spesifik, seperti klasifikasi sentimen, deteksi berita palsu, atau ekstraksi entitas.



Gambar 2.3 Pre-Training dan Fine-Tuning pada IndoBERT

Sumber: diolah dari Devlin dkk. (2018)

Gambar 2.3 menggambarkan proses *pre-training* dan *fine-tuning* pada model BERT. Dalam gambar tersebut, simbol $T_1, T_2 \dots T_N$ merepresentasikan

token-token dari kalimat pertama, sementara $T_1, T_2 \dots T_M$ menunjukkan token-token dari kalimat kedua. Setelah tahap *pre-training* selesai, proses dilanjutkan ke tahap *fine-tuning*. Pada tahap ini, terdapat tiga jenis tugas yang ditampilkan. Lapisan pertama adalah MNLI (*Multi-Genre Natural Language Inference*), bertugas untuk *Natural Language Inference* (NLI) yang bertujuan menentukan hubungan antara dua kalimat, apakah hubungan tersebut berupa kesimpulan (*entailment*), kontradiksi (*contradiction*), atau netral. Contohnya, mengevaluasi apakah kalimat B menyimpulkan, bertentangan dengan, atau netral terhadap kalimat A.

Lapisan kedua adalah NER (*Named Entity Recognition*), bertugas untuk mengenali entitas tertentu dalam teks, seperti nama orang, organisasi, atau lokasi. Sebagai ilustrasi, dalam kalimat "Presiden Prabowo sedang berada di Sumatra", model harus dapat mengidentifikasi bahwa "Prabowo" merupakan nama orang dan "Sumatra" merupakan nama lokasi. Lapisan ketiga adalah SQuAD (*Stanford Question Answering Dataset*), yang berfokus pada tugas *Question Answering*. Dalam tugas ini, model diminta menjawab pertanyaan berdasarkan konteks paragraf yang diberikan. Misalnya, dari sebuah paragraf dan pertanyaan yang menyertainya, model harus menemukan rentang kata (*span*) yang menjadi jawaban yang benar.

Selama *fine-tuning*, seluruh parameter model disesuaikan kembali berdasarkan karakteristik dan distribusi data baru. Hal ini memungkinkan model untuk mempertahankan kekuatan representasi umum dari *pre-training*, sekaligus menyesuaikan diri terhadap semantik dari domain tertentu. Teknik ini telah terbukti

efektif pada berbagai tugas NLP dan menjadi praktik standar dalam pengembangan model bahasa modern, termasuk pada penelitian ini yang menerapkan *fine-tuning* pada IndoBERT untuk tugas klasifikasi berita palsu.

2.5. Focal Loss

Focal Loss adalah *loss function* yang dirancang khusus untuk menangani permasalahan ketidakseimbangan kelas (*class imbalance*) dalam tugas klasifikasi, yang umum terjadi dalam domain seperti deteksi objek dan juga klasifikasi teks. Fungsi ini pertama kali diperkenalkan dalam konteks deteksi objek pada model RetinaNet (T. Y. Lin dkk., 2017), namun kini telah banyak diadaptasi dalam berbagai bidang, termasuk NLP. Dataset yang tidak seimbang, model cenderung mengutamakan prediksi terhadap kelas mayoritas dan mengabaikan kelas minoritas, yang sering kali menyebabkan rendahnya performa pada kelas minoritas

Focal Loss memodifikasi *cross-entropy loss* dengan memperkenalkan faktor penekanan terhadap sampel yang mudah diklasifikasikan. Hal ini dilakukan dengan menambahkan parameter pengatur (γ) yang mengurangi kontribusi dari sampel dengan probabilitas prediksi tinggi (artinya mudah diklasifikasi), sehingga model lebih fokus untuk belajar dari sampel yang sulit. Perhitungan *focal loss* dituliskan dalam persamaan 2.1

$$FL = -a_t(1 - p_t)^\gamma \log(p_t) \quad (2.1)$$

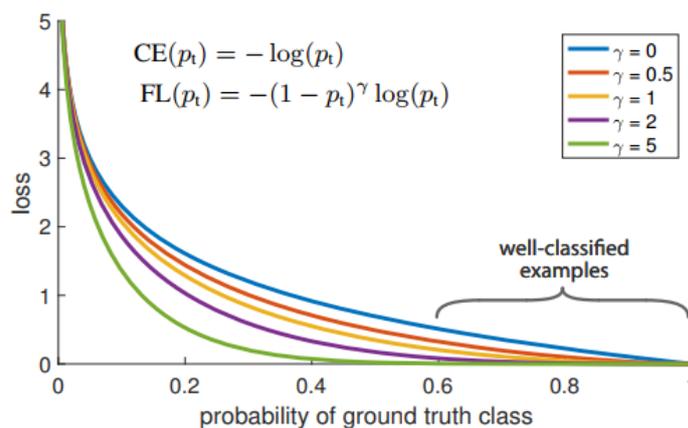
Keterangan:

- p_t : probabilitas prediksi untuk kelas yang benar
- γ : gamma (focus parameter)

a_t : balancing factor antara kelas

Dalam tugas klasifikasi teks, khususnya deteksi berita palsu, distribusi kelas sering kali tidak merata, misalnya jumlah berita benar lebih banyak dibandingkan berita palsu. Dalam konteks ini, penggunaan *focal loss* selama proses *fine-tuning* pada IndoBERT dapat membantu mengurangi bias terhadap kelas mayoritas, serta meningkatkan sensitivitas model terhadap sampel minoritas. Dengan demikian, integrasi *focal loss* menjadi langkah penting dalam mendesain sistem klasifikasi yang lebih seimbang dan akurat.

Untuk mengetahui keunggulan *focal loss* dibandingkan *cross entropy* dalam mengatasi data ketidakseimbangan data, peneliti menampilkan plot *loss* terhadap probabilitas prediksi benar pada data minoritas (hoaks). Ini membantu menunjukkan bagaimana *focal loss* menekan kontribusi dari prediksi yang mudah (benar dan sangat yakin), dan lebih fokus pada contoh sulit. Plot perbandingan *Cross Entropy* dengan *focal loss* ditunjukkan pada gambar 2.4



Gambar 2.4 perbandingan *Cross Entropy* dengan *Focal Loss*
 Sumber: T. Y. Lin dkk. (2017)

Secara matematis, *Focal Loss* merupakan modifikasi dari fungsi *Cross Entropy* (CE) dengan menambahkan faktor penekan $(1 - p_t)^\gamma$, di mana p_t adalah

probabilitas yang diprediksi untuk kelas yang benar dan γ adalah parameter yang mengontrol tingkat penekanan. Gambar 2.4 menunjukkan perbandingan antara fungsi *Cross Entropy* (dengan $\gamma=0$) dan *focal loss* untuk berbagai nilai γ . Terlihat bahwa semakin besar nilai γ , semakin rendah nilai *loss* untuk prediksi yang benar (probabilitas tinggi), sementara *loss* untuk prediksi yang salah tetap tinggi. Table 2.1. menunjukkan perbedaan antara nilai gamma dalam penelitian (T. Y. Lin dkk., 2017)

Tabel 2.1 perbedaan nilai gamma

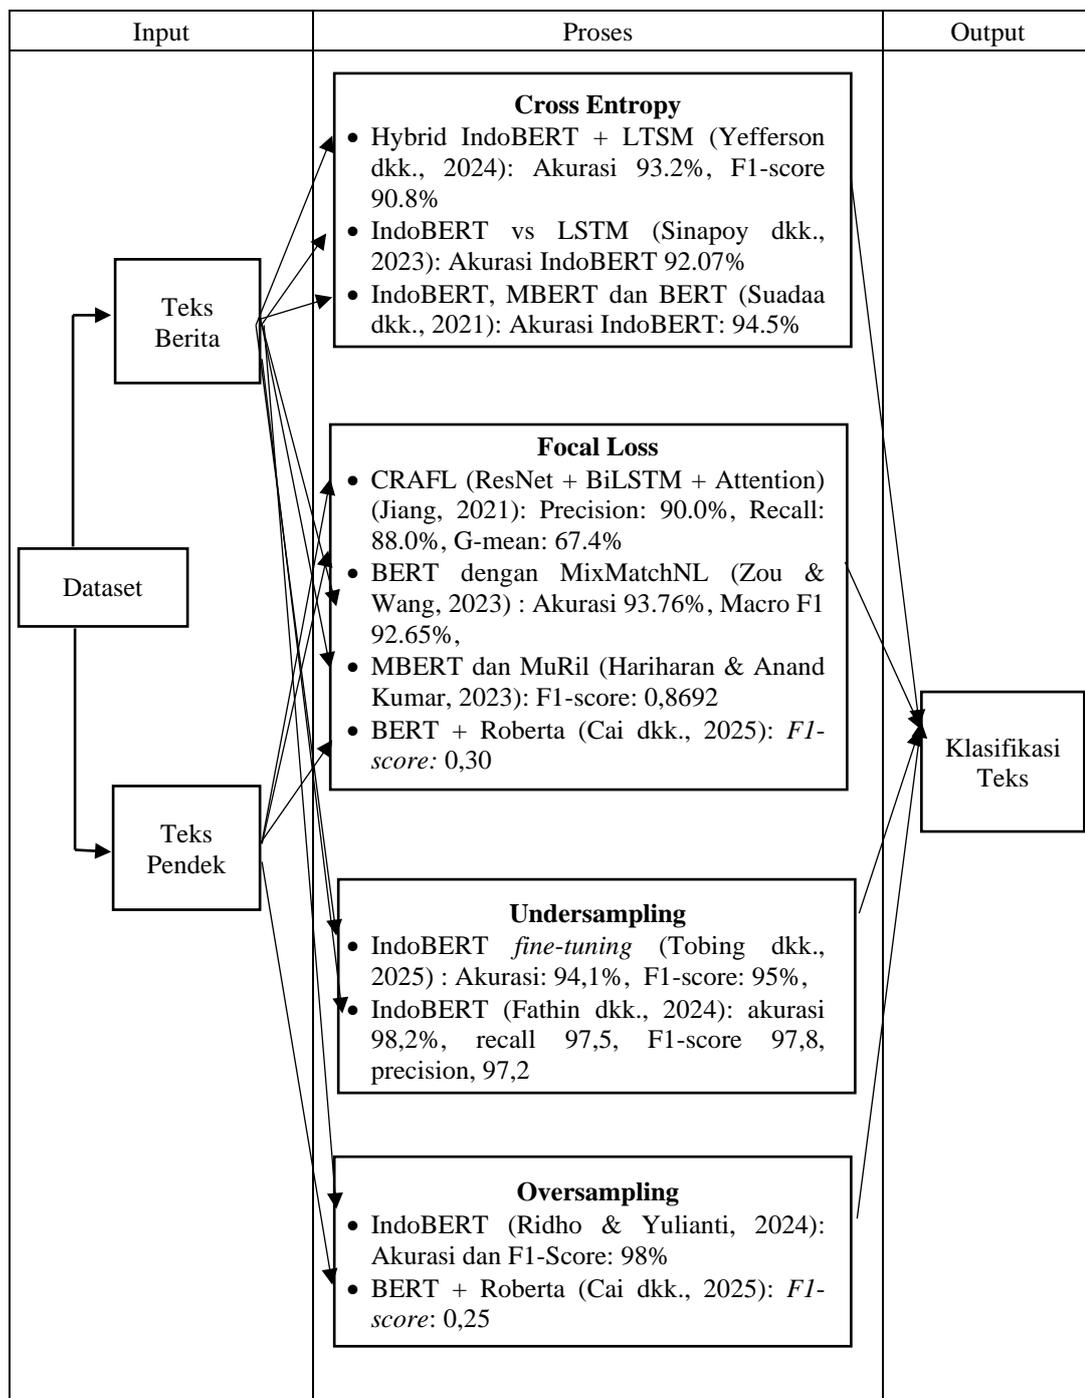
No	Gamma	Keterangan
1	0	Tidak ada penekanan, semua sampel dihitung normal
2	0,5	Sampel mudah masih ikut dihitung cukup besar
3	1	Memberi penalti sedang ke sampel yang mudah diklasifikasi.
4	2	Fokus kuat pada sampel sulit, kurangi bobot pada sampel mudah
5	5	Hampir sepenuhnya abaikan sampel mudah, hanya fokus pada sulit.

Dalam penelitian T. Y. Lin dkk. (2017) merekomendasikan nilai gamma sebesar 2, nilai tersebut seimbang untuk berfokus pada sampel sulit, tetapi tidak mengabaikan sampel yang mudah. Hal ini membuat model lebih peka terhadap kesalahan prediksi pada kelas minoritas. Pendekatan ini sangat relevan dalam konteks klasifikasi berita hoaks berbahasa Indonesia, di mana jumlah data hoaks biasanya jauh lebih sedikit dibandingkan dengan data non-hoaks. Dengan menggunakan *focal loss*, model dapat dilatih untuk memberikan perhatian lebih besar terhadap contoh kelas minoritas (hoaks) yang seringkali diabaikan dalam pendekatan konvensional berbasis *cross entropy*.

2.6. Kerangka Teori

Pada bagian ini akan sajikan teori-teori yang mendukung penelitian klasifikasi berita hoaks Bahasa Indonesia. Ada beberapa metode terbaik

berdasarkan penelitian sebelumnya yang akan dipilih dan akan digunakan dalam penelitian klasifikasi berita hoaks. kerangka teoritis klasifikasi berita hoaks ditampilkan pada gambar 2.5.



Gambar 2.5 Kerangka teori klasifikasi berita

Penelitian ini didasarkan pada beberapa teori utama yang saling berkaitan dan mendukung dalam menyelesaikan permasalahan klasifikasi berita hoaks berbahasa Indonesia. Proses klasifikasi dimulai dari pendekatan *Natural Language Processing* (NLP) yang memungkinkan komputer memahami dan mengolah bahasa alami, dalam hal ini teks berita Bahasa Indonesia. Salah satu tantangan dalam NLP adalah bagaimana merepresentasikan makna teks dalam bentuk yang dapat diproses oleh mesin. Untuk itu, digunakan model BERT (*Bidirectional Encoder Representations from Transformers*), yaitu model berbasis arsitektur *Transformer* yang mampu memahami konteks kata secara mendalam karena pembelajarannya dilakukan secara dua arah (*bidirectional*) dari kiri ke kanan dan dari kanan ke kiri, sehingga lebih mudah dalam memahami makna kalimat.

Dalam konteks Bahasa Indonesia, model yang digunakan adalah IndoBERT, yaitu *fine-tuning* dari BERT yang telah dilatih menggunakan korpus Bahasa Indonesia dalam skala besar. IndoBERT telah terbukti efektif untuk berbagai tugas NLP di Bahasa Indonesia, termasuk klasifikasi teks. Namun, dalam penelitian ini, data yang digunakan memiliki distribusi data yang tidak seimbang yaitu jumlah berita hoaks jauh lebih sedikit dari berita non-hoaks, yaitu 80% untuk data non-hoaks dan 20% untuk data hoaks. Ketidakseimbangan ini dapat menyebabkan model cenderung mengabaikan kelas minoritas. Oleh karena itu, digunakan *focal loss* sebagai fungsi *loss*, untuk memberi bobot lebih pada data yang sulit diklasifikasi (hoaks) karena proporsi data yang lebih sedikit. Dengan cara ini, diharapkan performa model pada kelas hoaks dapat ditingkatkan. penelitian ini diharapkan mampu menghasilkan model klasifikasi berita hoaks yang tidak hanya

akurat, tetapi juga mampu mengatasi tantangan umum dalam klasifikasi teks seperti ketidakseimbangan data dan kebutuhan pemahaman konteks yang mendalam terhadap Bahasa Indonesia.

2.7. Penelitian Terdahulu

Penelitian klasifikasi berita hoaks telah banyak dilakukan, dengan pendekatan dan karakteristik yang beragam. Dari hasil telaah terhadap tujuh penelitian terdahulu, diketahui bahwa para peneliti memanfaatkan berbagai fitur guna meningkatkan akurasi model klasifikasi yang digunakan. Tabel 2.2 menyajikan perbandingan fitur-fitur utama yang digunakan dalam penelitian-penelitian tersebut sebagai bahan kajian untuk merumuskan pendekatan yang relevan dalam studi ini..

Tabel 2.2. Perbandingan arsitektur penelitian terdahulu

No	Penulis	Fokus	Metode	Novelty	Akurasi
1.	Tobing dkk. (2025)	Deteksi berita hoaks tentang politik menggunakan IndoBERT.	<i>Fine-tuning</i> IndoBERT + <i>Undersampling</i>	Mengatasi data tidak seimbang dengan <i>undersampling</i>	94,1% dan ROC AUC 0,991.
2.	Yefferson dkk. (2024)	Kombinasi IndoBERT sebagai feature extractor dan LSTM sebagai classifier	IndoBERT-LSTM	Integrasi IndoBERT dengan LSTM untuk meningkatkan performa deteksi hoaks.	93,2%
3.	Ridho & Yulianti, (2024)	Perbandingan IndoBERT dengan model lain seperti CNN-LSTM, <i>Logistic Regression</i> , dan <i>Naive Bayes</i>	<i>Fine-tuning</i> IndoBERT + <i>oversampling</i> SMOTE	Penggunaan <i>oversampling</i> SMOTE untuk meningkatkan performa model pada data tidak seimbang.	Sebelum <i>oversampling</i> 92%, setelah <i>oversampling</i> 98%
4.	Fathin dkk. (2024)	Klasifikasi berita hoaks dengan dataset yang tidak seimbang, dengan metode IndoBERT	IndoBERT	Penerapan Random <i>Oversampling</i> dan Random <i>Undersampling</i> pada data tidak seimbang	98,2%

Lanjutan Tabel 2.2. Perbandingan arsitektur penelitian terdahulu

No	Penulis	Fokus	Metode	Novelty	Akurasi
5.	Zhang dkk. (2020)	Mendeteksi berita palsu secara multi modal	BDANN + VGG-19	Mendeteksi berita dengan multimodal, yaitu dengan teks (BERT) dan gambar (VGG-19)	85%
6.	Kaliyar dkk. (2021)	Meningkatkan performa deteksi berita palsu di media sosial	BERT + CNN	Integrasi BERT + CNN Paralel: Kombinasi unik dari BERT dan multi-kernel CNN sebagai arsitektur klasifikasi	98,90%
7.	Aggarwal dkk. (2020)	mengembangkan sistem klasifikasi berita hoaks secara otomatis dengan memanfaatkan <i>transfer learning</i> pada model BERT	BERT <i>fine tuning</i> + XGBoost dan LSTM	Penelitian membandingkan BERT dengan dua baseline (XGBoost dan LSTM)	97,02%
Arsitektur yang diusulkan		Klasifikasi berita hoaks Bahasa Indonesia.	IndoBERT <i>fine tuning</i> dengan pendekatan <i>Focal Loss</i>	Menggunakan model IndoBERT karena memiliki kemampuan representasi semantic secara menyeluruh, mendalam dan kontekstual, menjadikannya lebih unggul dalam menangani kompleksitas linguistik, pendekatan <i>focal loss</i> diterapkan untuk meningkatkan akurasi klasifikasi pada data yang tidak seimbang,	

Penelitian untuk mendeteksi berita hoaks pernah dilakukan oleh Tobing dkk. (2025) yang mengusulkan pendekatan *fine-tuning* pada model IndoBERT untuk mendeteksi berita hoaks politik berbahasa Indonesia. Penelitian ini memanfaatkan dataset dari Kaggle yang terdiri atas 20.928 berita fakta dan 2.251 berita hoaks yang diperoleh dari media daring CNN, Kompas, Tempo, dan Turnbackhoax. Dalam menangani data yang tidak seimbang, peneliti membandingkan dua pendekatan, yaitu pendekatan *undersampling* dan *class weighting*. Hasil evaluasi menunjukkan bahwa pendekatan *undersampling*

menghasilkan model dengan performa lebih stabil, mencapai akurasi sebesar 94,1% dan skor ROC AUC sebesar 0,991. Evaluasi menggunakan metrik evaluasi *confusion matrix*, *precision*, *recall*, dan *F1-score*. Meskipun menunjukkan hasil yang unggul, pendekatan *undersampling* mengorbankan sebagian besar data dari kelas non-hoaks, yang dapat mengurangi kemampuan generalisasi model. Selain itu, cakupan penelitian terbatas pada domain berita politik saja. Oleh karena itu, penelitian ini mengambil pendekatan berbeda dengan menerapkan fungsi *loss focal loss* untuk mengatasi ketidakseimbangan data tanpa menghilangkan informasi dari kelas non-hoaks, sehingga diharapkan dapat meningkatkan kinerja model secara menyeluruh dan adil pada kedua kelas.

Penelitian lain untuk mendeteksi berita hoaks juga pernah dilakukan oleh Yefferson dkk. (2024) yang mengusulkan model deteksi berita hoaks berbahasa Indonesia dengan pendekatan *hybrid* antara IndoBERT sebagai *feature extractor* dan *Long Short-Term Memory* (LSTM) sebagai *classifier*. Dataset yang digunakan terdiri dari 3.878 data hoaks yang diambil dari situs *turnbackhoax.id* dan 1.998 data fakta dari CNN Indonesia, dengan total 5.876 data. Dataset dibagi menjadi dua bagian dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Hasil evaluasi menunjukkan bahwa model IndoBERT-LSTM mencapai akurasi sebesar 93,2%, *precision* sebesar 92%, *recall* sebesar 89,7%, dan *F1-score* sebesar 90,8%, lebih unggul dibandingkan model pembanding seperti IndoBERT-BiLSTM dan LSTM murni. Meskipun demikian, penelitian ini tidak secara eksplisit membahas penanganan terhadap ketidakseimbangan data antar kelas, di mana jumlah berita hoaks jauh lebih banyak dibandingkan berita fakta. Selain itu, belum dilakukan

analisis terhadap kesalahan prediksi seperti *false positives* dan *false negatives*, serta tidak ada pembahasan mengenai perbandingan fungsi *loss* yang digunakan. Berdasarkan kekurangan tersebut, penelitian ini menjadi relevan sebagai dasar bagi pengembangan penelitian yang penulis lakukan, yang berfokus pada peningkatan kinerja klasifikasi hoaks dengan menerapkan fungsi *focal loss* pada proses *fine-tuning* IndoBERT, untuk mengatasi permasalahan data tidak seimbang secara langsung.

Penelitian lain oleh Ridho & Yulianti (2024) mengusulkan pendekatan deteksi berita hoaks berbahasa Indonesia dengan membandingkan model IndoBERT (versi *Base* dan *Large*) pada berbagai algoritma pembandingan seperti CNN-LSTM, *Logistic Regression*, *Naive Bayes*, *Decision Tree*, dan *Random Forest*. Dataset yang digunakan terdiri dari 600 artikel berita, yang tidak seimbang (372 valid dan 228 hoaks), dan dilakukan penyeimbangan data menggunakan teknik SMOTE. Hasil evaluasi menunjukkan bahwa model IndoBERT Large memberikan performa terbaik, dengan akurasi sebesar 98%, *precision* 98%, *recall* 97%, dan *F1-score* 98% setelah penerapan SMOTE. Sementara itu, model IndoBERT Base menghasilkan akurasi 97% dan *F1-score* 96%. Model-model tradisional seperti *Naive Bayes* hanya mencapai akurasi 78%, dan CNN-LSTM mengalami penurunan performa menjadi 44% akibat *overfitting* terhadap data sintetik. Penelitian ini menegaskan keunggulan arsitektur *transformer* dalam memahami konteks linguistik Bahasa Indonesia. Namun, penggunaan SMOTE memiliki keterbatasan dalam hal potensi *overfitting* dan ketergantungan pada data buatan. Oleh karena itu, penelitian menjadi dasar penting bagi penelitian ini, yang mengusulkan penggunaan

focal loss sebagai alternatif metode penanganan data tidak seimbang tanpa perlu menciptakan data sintetik, sehingga dapat menjaga generalisasi model dan meningkatkan ketahanan klasifikasi terhadap kelas minoritas (hoaks).

Penelitian lainnya dalam klasifikasi berita hoaks dilakukan oleh Fathin dkk. (2024) berfokus pada klasifikasi berita hoaks politik berbahasa Indonesia menggunakan model IndoBERT dan menangani masalah ketidakseimbangan data melalui teknik *resampling*. Dataset yang digunakan terdiri dari 27.747 artikel, dengan distribusi tidak seimbang antara 6.947 hoaks dan 20.945 non-hoaks. Peneliti menerapkan dua pendekatan penyeimbangan data, yaitu *Random Undersampling* (RUS) dan *Random Oversampling* (ROS), dan mengevaluasi performa model IndoBERT setelah proses *fine-tuning*. Hasil penelitian menunjukkan bahwa penggunaan RUS menghasilkan performa terbaik dengan akurasi 98,2%, *recall* 97,8%, dan *F1-score* 97,5%. Meskipun hasilnya sangat baik, pendekatan ini memiliki keterbatasan, terutama pada risiko hilangnya informasi penting akibat penghapusan data saat *undersampling*, atau *overfitting* akibat duplikasi data saat *oversampling*. Berdasarkan kekurangan tersebut, penelitian ini menjadi landasan penting bagi penelitian yang akan dilakukan, yang menggunakan fungsi *loss focal loss* sebagai alternatif untuk menangani data tidak seimbang tanpa manipulasi jumlah data, serta mempertahankan konteks asli dari masing-masing kelas, khususnya untuk mendeteksi hoaks yang jarang muncul namun berdampak besar.

Penelitian tentang berita hoaks pernah dilakukan oleh Zhang dkk. (2020) mengusulkan model BDANN (*BERT-Based Domain Adaptation Neural Network*) sebagai pendekatan deteksi berita hoaks berbasis *multi-modal*, yaitu

menggabungkan fitur dari teks dan gambar sekaligus. BDANN menggunakan model BERT sebagai ekstraktor fitur teks, dan VGG-19 untuk fitur visual, serta menambahkan komponen domain *classifier* guna mengurangi ketergantungan terhadap topik atau event tertentu. Eksperimen dilakukan pada dua dataset besar, yaitu Twitter dan Weibo, dan menunjukkan bahwa BDANN mampu mengungguli berbagai baseline terkini seperti att-RNN, EANN, dan MVAE, dengan akurasi tertinggi sebesar 86,5% dan *F1-score* 88% pada dataset Weibo. Penelitian ini menyoroti pentingnya penggunaan fitur *multi-modal* dan teknik adaptasi domain. Namun, pendekatan ini belum menangani ketidakseimbangan data secara eksplisit dan belum menguji efektivitasnya pada konteks Bahasa Indonesia. Oleh karena itu, hasil penelitian yang menyebutkan keunggulan BERT menjadi pijakan relevan bagi penelitian ini, yang berfokus pada klasifikasi berita hoaks berbahasa Indonesia dengan IndoBERT dan pendekatan *focal loss*, sebagai solusi untuk mengatasi tantangan data tidak seimbang pada klasifikasi berbasis teks

Penelitian selanjutnya dilakukan oleh Kaliyar dkk. (2021) mengusulkan model *FakeBERT*, yaitu gabungan antara BERT dan CNN satu dimensi (1D-CNN) untuk mendeteksi berita hoaks pada media sosial. Model ini dirancang dengan tiga blok CNN paralel yang menangkap informasi semantik dari representasi BERT dengan kernel dan filter yang bervariasi. Dataset yang digunakan merupakan data nyata dari Kaggle, berjumlah 20.800 artikel, dengan distribusi kelas yang seimbang antara berita non-hoaks dan hoaks. Hasil evaluasi menunjukkan bahwa *FakeBERT* memberikan akurasi tertinggi sebesar 98,90%, mengungguli model lain seperti LSTM, CNN, serta model klasik seperti *Naive Bayes* dan *Random Forest*.

Meskipun hasil akurasi sangat tinggi, penelitian ini tidak mempertimbangkan permasalahan ketidakseimbangan data, yang lazim ditemukan pada kasus deteksi hoaks di dunia nyata. Selain itu, pendekatan ini belum diterapkan pada data berbahasa Indonesia. Oleh karena itu, hasil penelitian menjadi dasar penting bagi pengembangan penelitian ini, yang mengusulkan penggunaan IndoBERT dengan pendekatan *focal loss* untuk menangani ketidakseimbangan data dalam klasifikasi berita hoaks berbahasa Indonesia secara lebih akurat dan adil.

Penelitian selanjutnya dilakukan oleh Aggarwal dkk. (2020) mengusulkan pendekatan deteksi berita hoaks dengan memanfaatkan teknik *fine-tuning* pada model BERT untuk klasifikasi biner antara berita “Fake” dan “Real”. Dataset yang digunakan adalah NewsFN yang terdiri dari 6.210 artikel berita berbahasa Inggris dengan distribusi seimbang antar kelas. Penelitian ini membandingkan performa BERT terhadap dua model pembanding, yaitu XGBoost dan LSTM. Hasil eksperimen menunjukkan bahwa model *fine-tuned* BERT mencapai akurasi tertinggi sebesar 97,02% dan ROC AUC 0,99, jauh melampaui akurasi XGBoost (89,37%) dan LSTM (86,23%). Penelitian ini membuktikan efektivitas pendekatan *transfer learning* pada tugas klasifikasi berita hoaks, bahkan dengan *pre-processing* minimal. Namun demikian, pendekatan ini belum mengeksplorasi kasus ketidakseimbangan data, yang menjadi tantangan penting dalam klasifikasi hoaks di dunia nyata. Hasil penelitian menunjukkan kelebihan BERT dalam klasifikasi data yang menjadi dasar penting bagi pengembangan penelitian ini yang berfokus pada penerapan IndoBERT sebagai model dasar dengan pendekatan *focal loss* untuk mengatasi ketidakseimbangan data hoaks berbahasa Indonesia.

Berdasarkan penjelasan pada masing-masing penelitian yang tercantum dalam tabel 2.2, penelitian ini mengusulkan pendekatan baru dalam klasifikasi berita hoaks berbahasa Indonesia dengan menerapkan *fine-tuning* pada model IndoBERT serta mengintegrasikan *focal loss* sebagai *loss function*. Pendekatan ini dirancang untuk mengatasi isu ketidakseimbangan kelas yang umum terjadi pada data berita hoaks, di mana jumlah berita palsu jauh lebih sedikit dibandingkan berita non-hoaks. Proses *fine-tuning* memungkinkan model untuk menyesuaikan diri secara lebih optimal terhadap domain spesifik dan meningkatkan akurasi klasifikasi (Rogers dkk., 2020). Selain itu, pendekatan ini juga berpotensi menurunkan tingkat kesalahan klasifikasi seperti *false positive* dan *false negative* melalui pemahaman konteks yang lebih mendalam, yang tidak dapat dicapai secara optimal oleh model *pre-trained* tanpa penyesuaian.

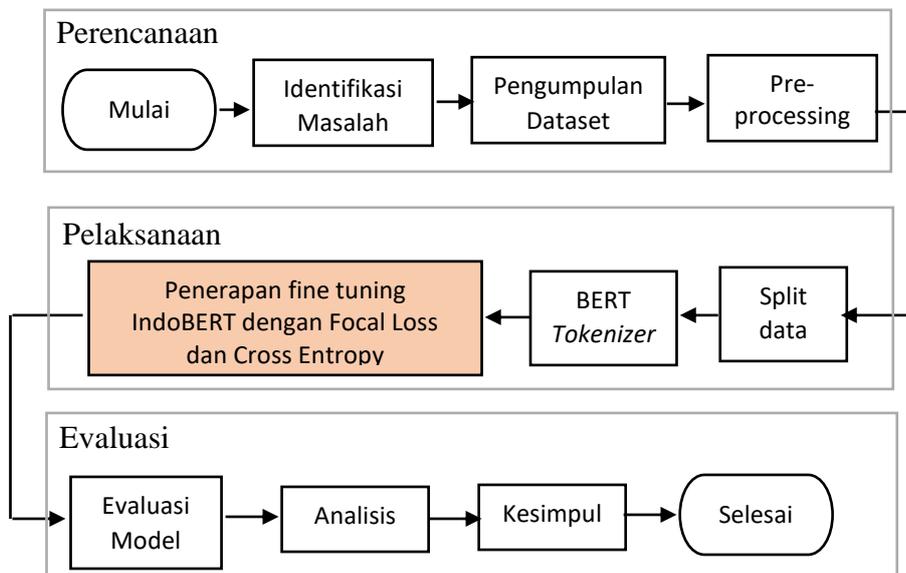
Kebaruan dari penelitian ini terletak pada penerapan *focal loss* dalam pelatihan model IndoBERT, yang ditujukan untuk memberikan perhatian lebih besar pada data-data sulit yang sering terklasifikasi secara tidak tepat. Hingga saat ini, belum ditemukan studi yang secara eksplisit mengimplementasikan *focal loss* pada IndoBERT dalam konteks klasifikasi berita hoaks berbahasa Indonesia. Sebagian besar studi sebelumnya mengandalkan teknik penyeimbangan buatan, seperti *undersampling* atau *oversampling*, yang berpotensi mengubah distribusi alami data. Penelitian ini menggunakan data dengan distribusi kelas yang tetap alami, untuk menilai secara lebih representatif sejauh mana *focal loss* mampu mengatasi permasalahan ketidakseimbangan data.

BAB III

METODOLOGI PENELITIAN

3.1 Tahapan Penelitian

Penelitian ini menerapkan model IndoBERT untuk melakukan klasifikasi terhadap teks berita berbahasa Indonesia, untuk membedakan antara berita hoaks dan yang berita non-hoaks. Pengembangan dan evaluasi model dilakukan melalui tahapan metodologis yang sistematis untuk memastikan keandalan performa model dalam konteks klasifikasi tersebut. Tahapan dalam penelitian ini dapat dilihat pada gambar 3.1



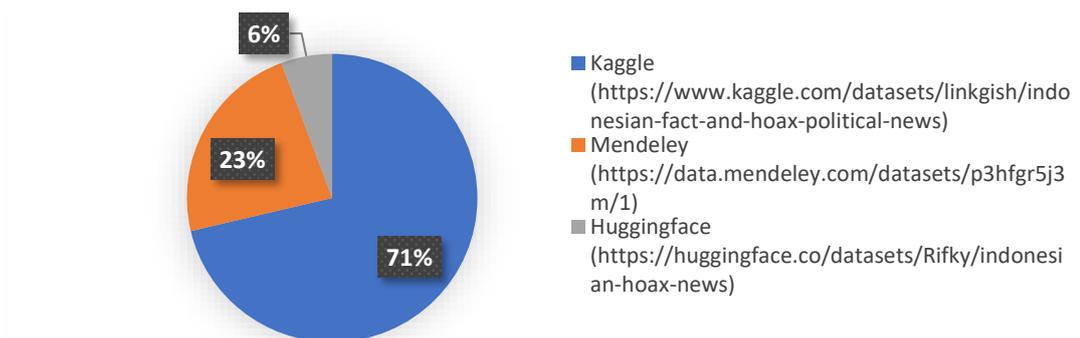
Gambar 3.1 Tahapan penelitian

3.1.1 Perencanaan

Tahap perencanaan merupakan langkah awal dalam pelaksanaan penelitian ini. Pada tahap ini, fokus diarahkan pada permasalahan meningkatnya penyebaran berita hoaks di media daring. Fenomena ini terjadi karena kurangnya pengetahuan

masyarakat mengenai kebenaran informasi yang mereka bagikan. Oleh karena itu, diperlukan suatu solusi yang efektif guna menekan laju penyebaran berita hoaks tersebut yaitu dengan membuat deteksi untuk klasifikasi berita hoaks Bahasa Indonesia.

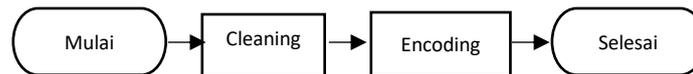
Langkah selanjutnya dalam penelitian adalah mengumpulkan dataset, Penelitian ini menggunakan dataset sekunder berupa kumpulan berita berbahasa Indonesia yang telah diberi label ke dalam dua kategori utama, yaitu berita faktual dan berita hoaks. Sumber data berasal dari tiga platform daring yang umum digunakan dalam penelitian data sains, yakni Kaggle, Mendeley, dan Huggingface. Ketiga sumber ini menyediakan dataset yang telah melalui proses penyaringan dan pengolahan serta pemberian label, sehingga data siap digunakan untuk keperluan analisis lebih lanjut. Proporsi data menunjukkan adanya ketidakseimbangan kelas, dengan 80% merupakan berita non-hoaks dan 20% merupakan berita hoaks. Jumlah data dari tiga platform dapat pada gambar 3.2.



Gambar 3.2. Komposisi penggabungan data

Perbedaan jumlah antara berita hoaks dan non-hoaks menunjukkan bahwa dataset bersifat tidak seimbang, yang berpotensi mempengaruhi kinerja model dalam mendeteksi kelas minoritas (berita hoaks). Ketidakseimbangan ini menjadi pertimbangan dalam pemilihan metode pelatihan model, khususnya dalam

penggunaan *loss function* yang dapat mengatasi dominasi kelas mayoritas. Setelah data terkumpul, tahap selanjutnya adalah *pre-processing*. Sebelum dataset diterapkan pada model, perlu dilakukan pre-processing terlebih dahulu, tahap pre-processing dapat dilihat pada gambar 3.3.



Gambar 3.3 Tahapan *Pre-procesing*

- a. Proses *cleaning* data dilakukan pada tahap awal dengan tujuan untuk meningkatkan kualitas data sehingga hasil pelatihan model dapat lebih optimal. Pembersihan teks ini bertujuan untuk menghilangkan elemen-elemen yang tidak relevan atau tidak memiliki makna penting dalam konteks klasifikasi teks. Beberapa tahapan dalam proses *cleaning* meliputi, penghapusan URL, penghapusan angka, penghapusan karakter tanda baca (kecuali tanda koma dan titik), mengganti baris baru dengan spasi, menghapus spasi yang berlebih, menghapus karakter yang berulang dan merubah huruf besar menjadi kecil. Langkah-langkah tersebut dilakukan karena kata-kata tersebut tidak memiliki makna dan supaya tidak mempengaruhi hasil klasifikasi. Pada proses *cleaning* tetap mempertahankan tanda koma dan titik untuk lebih mempertahankan konteks dan makna kalimat, Hal ini didasarkan pada pertimbangan bahwa model IndoBERT dilatih menggunakan teks berbahasa Indonesia yang mempertahankan struktur kalimat lengkap dengan tanda baca. Oleh karena itu, menjaga keberadaan tanda koma dan titik dianggap penting agar model dapat memahami konteks, struktur kalimat, serta makna kata dalam hubungannya dengan keseluruhan kalimat secara lebih akurat, bukan hanya sekadar

mengenalikan urutan kata. Pendekatan ini sejalan dengan karakteristik model berbasis Transformer yang sangat bergantung pada konteks dalam memproses informasi. Contoh hasil *cleaning* dapat dilihat pada tabel 3.1.

Tabel 3.1. Hasil *cleaning* data

Berita	Cleaning Data
Jakarta, CNN Indonesia -- Ketua Umum Partai Demokrat, Agus Harimurti Yudhoyono (AHY) mengaku senang partainya kembali mendapat nomor urut 14 untuk Pemilu 2024. Hal itu disampaikan AHY pada Rabu (14/12) di Kantor Komisi Pemilihan Umum (KPU), Jakarta. Dalam pidatonya usai penetapan nomor urut di kantor KPU, AHY menyampaikan bahwa semua pihak akan kembali berjumpa dengan Partai Demokrat pada 14 Februari 2024. Tanggal tersebut merujuk pada hari pemungutan suara Pemilu 2024. "Saya juga ingin menyampaikan bahwa Demokrat mendapat kembali nomor 14. Nomor ini juga tentunya spesial karena hari ini kita di tanggal 14 Desember dan bertemu kembali Februari," kata AHY dalam sambutannya, Rabu (14/12).	jakarta, cnn indonesia ketua umum partai demokrat, agus harimurti yudhoyono ahy mengaku senang partainya kembali mendapat nomor urut untuk pemilu. hal itu disampaikan ahy pada rabu di kantor komisi pemilihan umum kpu, jakarta. dalam pidatonya usai penetapan nomor urut di kantor kpu, ahy menyampaikan bahwa semua pihak akan kembali berjumpa dengan partai demokrat pada february. tanggal tersebut merujuk pada hari pemungutan suara pemilu .saya juga ingin menyampaikan bahwa demokrat mendapat kembali nomor . nomor ini juga tentunya spesial karena hari ini kita di tanggal desember dan bertemu kembali february, kata ahy dalam sambutannya, rabu .

- b. *Encoding* merupakan langkah untuk mengubah data dari kolom klasifikasi menjadi format numerik (angka) yang bisa dipahami oleh model machine learning. Ini penting karena sebagian besar algoritma *machine learning*, termasuk model *deep learning*, hanya bisa menerima input dalam bentuk angka, bukan teks atau simbol. Proses *encoding* pada penelitian ini dilakukan dengan menambahkan kolom baru yang berisi nilai "0" untuk berita non-hoaks dan nilai "1" untuk berita hoaks. Nilai ini ditentukan berdasarkan informasi yang ada pada kolom klasifikasi yang mengelompokkan data ke dalam kategori non-hoaks dan hoaks. Contoh hasil *encoding* dapat dilihat pada tabel 3.2.

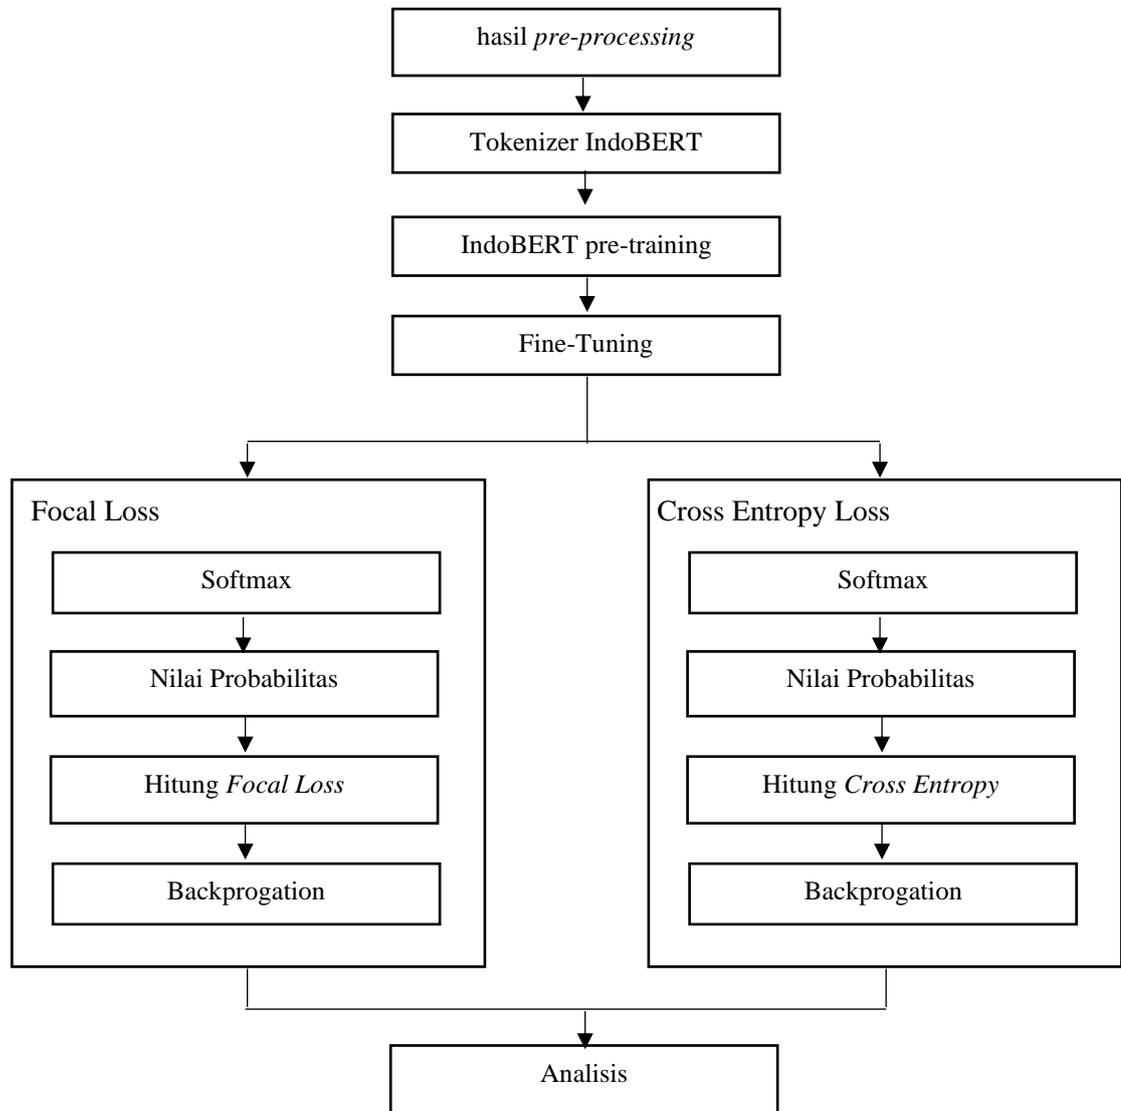
Tabel 3.2. *Encoding dataset*

Klasifikasi	Berita	Label
Non-hoaks	jakarta, cnn indonesia ketua umum partai demokrat, agus harimurti yudhoyono ahy mengaku senang partainya kembali	0
Hoaks	gambar hasil suntingan dari artikel berjudul munarman sayangkan teroris ditembak mati, presiden jokowi	1
Non-hoaks	sekretaris jenderal pdip haso kristiyanto mengatakan pertemuan presiden jokowi dan ketua dpc pdip kota solo	0
hoaks	video hasil suntingan. pihak yang berada dalam video bukanlah erick thohir melainkan jay	1

3.1.2 Pelaksanaan

Pada tahap pelaksanaan, terdapat beberapa langkah yang perlu disesuaikan dengan kebutuhan pemodelan menggunakan IndoBERT. Langkah pertama yang dilakukan adalah proses pembagian data (*data splitting*). Data yang telah melewati tahap *pre-processing* selanjutnya dibagi menjadi tiga bagian, yaitu data pelatihan, data validasi, dan data pengujian. Rasio yang umum digunakan dalam penelitian yang menggunakan model BERT yaitu 80% data training, 10% data validasi, dan 10% data testing (Verma dkk., 2023; Raza dkk., 2025). Dalam penelitian klasifikasi berita hoaks ini menggunakan dua skenario dalam proses pengujian, yaitu rasio data 70:15:15 (70% data *training*, 15% data validasi dan 15% data *testing*) dan 80:10:10 (80% data *training*, 10% data validasi, dan 10% data *testing*). Pembagian data harus seimbang untuk memberikan cukup data untuk melatih model, dan masih menyisihkan data untuk validasi dan pengujian untuk menghindari *overfitting* dan memastikan model berjalan dengan baik. Penelitian ini memanfaatkan pendekatan *fine-tuning* pada model IndoBERT untuk proses pelatihan, dengan penerapan *focal loss* sebagai fungsi *loss* utama. Selain itu, digunakan *cross entropy loss* sebagai

pembandingan untuk mengevaluasi performa model. Gambar 3.4 menunjukkan desain model dalam penelitian klasifikasi ini.

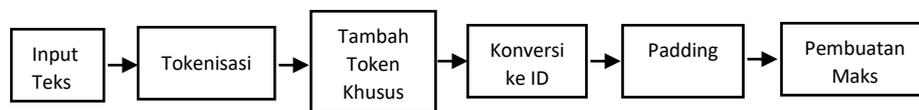


Gambar 3.4. Desain model

a. *Tokenize BERT*

Proses tokenisasi pada BERT bertujuan untuk mengubah teks mentah menjadi bentuk yang dapat diproses oleh model. Tokenisasi dilakukan dengan memecah kalimat menjadi bagian-bagian kecil yang disebut token. Pada BERT, tokenisasi menggunakan metode WordPiece, yang secara otomatis memecah kata

menjadi sub-kata atau morfem ketika kata tersebut tidak ditemukan dalam kosakata model. Proses ini diawali dengan menambahkan token khusus seperti [CLS] di awal dan [SEP] di akhir kalimat. Token yang dihasilkan kemudian dikonversi menjadi indeks numerik berdasarkan kamus BERT. Dengan demikian, model dapat memahami konteks dan makna dari kata-kata dalam kalimat. Alur proses tokenisasi dapat dilihat pada gambar 3.5



Gambar 3.5 Alur Proses Tokenisasi

Teks input berupa kalimat mentah akan melalui beberapa tahap sebelum dimasukkan ke dalam model BERT. Tahap pertama adalah tokenisasi dengan metode *WordPiece* untuk memecah kalimat menjadi token. Kemudian, token khusus [CLS] ditambahkan di awal untuk menandai awal teks dan [SEP] di akhir teks untuk menandai batas akhir. Selanjutnya token dikonversi menjadi indeks numerik (token ID) sesuai kamus BERT. Jika panjang kalimat kurang dari batas maksimum, *padding* dilakukan dengan menambahkan token [PAD] untuk menyamakan panjang semua input. Tahap terakhir, *masking* diterapkan untuk menandai posisi [PAD] agar bagian tersebut diabaikan selama pemrosesan model. Tabel 3.3 menunjukkan hasil tokenisasi.

Tabel 3.3 Hasil Tokenisasi BERT

Langkah	Hasil
Teks asli	jakarta, cnn indonesia ketua umum partai demokrat, agus harimurti yudhoyono ahy mengaku senang partainya kembali
Tokenisasi	['jakarta', ',', 'cn', '##n', 'indonesia', 'ketua', 'umum', 'partai', 'demokrat', ',', 'agus', 'hari', '##mur', '##ti', 'yudhoyono', 'ah', '##y', 'mengaku', 'senang', 'partainya', 'kembali']

Lanjutan Tabel 3.3 Hasil Tokenisasi BERT

Langkah	Hasil
Token Khusus	'[[CLS]', 'jakarta', ',', 'cn', '##n', 'indonesia', 'ketua', 'umum', 'partai', 'demokrat', ',', 'agus', 'hari', '##mur', '##ti', 'yudhoyono', 'ah', '##y', 'mengaku', 'senang', 'partainya', 'kembali', '[SEP]']
Konversi Token IDs	[2, 678, 30468, 18929, 30355, 300, 2120, 752, 2304, 8851, 30468, 1661, 406, 5586, 87, 13383, 1129, 30371, 2463, 3000, 26857, 755, 3]
Padding	[2, 678, 30468, 18929, 30355, 300, 2120, 752, 2304, 8851, 30468, 1661, 406, 5586, 87, 13383, 1129, 30371, 2463, 3000, 26857, 755, 3, 0, 0]
Attention Mask	[1, 0, 0]

b. Pelatihan model

Pelatihan model klasifikasi dengan IndoBERT dilakukan menggunakan arsitektur *Transformer* yang menerapkan pelatihan dua arah (*bidirectional training*), memungkinkan model untuk mempertimbangkan konteks kata baik dari sisi kiri maupun kanan secara bersamaan. Pendekatan ini membuat IndoBERT sangat efektif dalam memahami makna kalimat secara mendalam. Model BERT sendiri sangat bergantung pada mekanisme *self-attention*, yang berfungsi untuk menyoroti hubungan antara kata-kata dalam teks. Pada tahap ini, model IndoBERT *pre-trained* dimuat menggunakan fungsi *BertForSequenceClassification* dari library Transformers. Model ini mengambil arsitektur IndoBERT yang telah dilatih sebelumnya untuk bahasa Indonesia, dengan jumlah parameter sebesar 124.443.651, yang mencakup lapisan *embedding*, *self-attention*, dan *feed-forward*. Model dapat dimuat dengan skrip yang ditunjukkan pada gambar 3.6.

```

from transformers import BertForSequenceClassification
model = BertForSequenceClassification.from_pretrained
(
    "indobenchmark/indobert-base-p1", num_labels=2
)

```

Gambar 3.6. Potongan kode memanggil model dengan library *transformer*

Kode ini menginisialisasi model dengan dua kelas untuk klasifikasi berita fakta dan hoaks, sesuai dengan kebutuhan penelitian. Model menggunakan tokenisasi yang telah dilakukan pada tahap sebelumnya untuk mengonversi teks menjadi token numerik, memungkinkan proses pelatihan dilakukan secara efisien. Algoritma *Adam Optimizer (Adaptive Moment Estimation)* digunakan dalam proses pelatihan, dengan *learning rate* sebesar $2e-5$ untuk memperbarui bobot model secara bertahap. *Adam Optimizer* adalah salah satu teknik optimasi yang populer dalam *deep learning* karena kemampuannya untuk beradaptasi dengan perubahan gradien selama pelatihan. Algoritma ini menggabungkan dua metode utama, yaitu momentum dan *RMSProp*, untuk memperkirakan nilai rata-rata dan standar deviasi dari gradien. Algoritma *Adam Optimizer* mampu bekerja secara cepat dan efisien dalam mengoptimalkan model (Kingma & Ba, 2015), Formulasi dasar *Adam Optimizer* ditunjukkan pada persamaan 3.1 sampai 3.4.

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (3.1)$$

$$v_t = \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (3.2)$$

$$m_t = \frac{m_t}{1 - \beta_1^t}, \quad v_t = \frac{v_t}{1 - \beta_2^t} \quad (3.3)$$

$$\theta_t = \theta_{t-1} - a \cdot \frac{m_t}{\sqrt{v_t} - \epsilon} \quad (3.4)$$

Pada persamaan 3.1 m_t merepresentasikan *moving average* dari gradien saat ini (momentum pertama), kemudian m_{t-1} sebagai nilai *moving average* (momentum pertama) sebelumnya, kemudian symbol β_1 sebagai nilai beta 1, dan g_t sebagai gradien dari loss function terhadap waktu t . sementara, pada rumus

kedua 3.2, terdapat symbol v_t yaitu moving average dari gradien kuadrat atau disebut sebagai momentum kedua, kemudian terdapat β_2 sebagai nilai beta 2, kemudian v_{t-1} sebagai nilai momentum kedua sebelumnya dan g_t^2 merupakan kuadrat gradien dari loss function terhadap parameter waktu t . Komponen ini adalah inti dari pendekatan RMSProp, yang berfokus pada penyesuaian skala pembaruan parameter berdasarkan variansi gradien untuk menjaga stabilitas pelatihan. Pada rumus ketiga 3.3, dilakukan koreksi bias untuk nilai m_t dan v_t yang bertujuan untuk memperbaiki bias awal karena kedua nilai ini cenderung bernilai nol pada langkah-langkah awal pelatihan. Terakhir, pada rumus keempat 3.4, parameter model diperbarui kombinasi antara momentum pertama dan RMSProp digunakan untuk menentukan langkah pembaruan, di mana a adalah learning rate yang menentukan seberapa besar pembaruan bobot pada setiap langkah, dan ϵ adalah konstanta kecil untuk mencegah pembagian dengan nol, memastikan stabilitas selama proses pelatihan

c. Fine Tuning dengan Focal Loss

Dalam penelitian ini, proses *fine-tuning* model IndoBERT dilakukan dengan menggunakan *focal loss* sebagai fungsi *loss* utama. *Focal Loss* dipilih karena kemampuannya dalam menangani permasalahan ketidakseimbangan kelas, yang sering ditemukan dalam data berita hoaks. Berikut adalah tahapan alur pelatihan model dengan *focal loss*:

1. Softmax

Setelah teks masukan diproses melalui *tokenizer* dan diteruskan ke model IndoBERT, keluaran model berupa logit (nilai linear dari layer terakhir) akan

diteruskan ke fungsi softmax. Fungsi ini mengubah *logit* menjadi nilai probabilitas antar kelas. persamaan *softmax* berfungsi sebagai metode perhitungan probabilitas dalam proses pelatihan model klasifikasi. Persamaan *softmax* pada 3.5.

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.5)$$

Keterangan:

z_i adalah logit kelas ke- i

K adalah jumlah kelas

$P(y_i)$ adalah probabilitas prediksi untuk kelas tersebut.

2. Nilai Probabilitas

Nilai probabilitas adalah hasil dari persamaan *softmax* yang menunjukkan tingkat keyakinan model terhadap masing-masing kelas (hoaks atau non-hoaks). Nilai probabilitas ini akan digunakan dalam penghitungan *loss* dengan *focal loss*.

3. Perhitungan *Focal Loss*

Focal Loss digunakan untuk menghitung seberapa besar kesalahan prediksi yang dilakukan model. Berbeda dengan *Cross Entropy*, *Focal Loss* mengurangi kontribusi dari sampel yang mudah diklasifikasikan, dan memberikan penekanan lebih besar pada sampel yang sulit diklasifikasikan. Persamaan 3.6 menunjukkan perhitungan yang digunakan *focal loss*.

$$FL = -a_t(1 - p_t)^\gamma \log(p_t) \quad (3.6)$$

Keterangan:

p_t : probabilitas prediksi untuk kelas yang benar

γ : focus parameter

α_t : balancing factor antara kelas
 $(1 - p_t)^\gamma$: komponen memperkecil loss pada sampel yang mudah diprediksi

Dengan demikian, *Focal Loss* mendorong model untuk lebih fokus pada contoh-contoh sulit yang selama ini kurang diperhatikan oleh fungsi loss standar seperti *Cross Entropy*

4. Backpropagation

Hasil loss yang dihitung menggunakan Focal Loss akan digunakan dalam proses backpropagation, yaitu proses propagasi mundur untuk menghitung gradien dan memperbarui bobot model. Proses ini dilakukan menggunakan algoritma optimisasi seperti *AdamW*, agar bobot model secara bertahap mengarah pada nilai yang meminimalkan loss

d. Fine Tuning dengan *Cross Entropy*

Proses *fine-tuning* yang dilakukan pada model *cross entropy* sama dengan pada model *focal loss*, perbedaan hanya pada proses perhitungan *loss*. *Cross Entropy Loss* menghitung selisih antara distribusi probabilitas prediksi dengan distribusi label sebenarnya. Semakin besar perbedaan antara probabilitas prediksi dan label yang benar, semakin besar pula nilai *loss* yang dihasilkan. Persamaan 3.7 menunjukkan perhitungan yang dilakukan oleh model *cross entropy*.

$$CE(p_t) = -\log(p_t) \quad (3.7)$$

Cross Entropy Loss hanya bergantung pada probabilitas prediksi terhadap label yang benar (p_t) Jika model sangat yakin dan benar (misalnya $p_t = 0.99$), maka *loss*

menjadi kecil. Namun jika model salah atau ragu-ragu (misalnya $p_t = 0.2$) maka *loss* menjadi besar

3.1.3 Evaluasi

Evaluasi dilakukan untuk mengukur kinerja model dalam melakukan klasifikasi terhadap data berita hoaks dan fakta. Pada penelitian ini, digunakan dua metode evaluasi utama, yaitu *classification report* dan *confusion matrix*, yang secara bersama-sama memberikan gambaran kuantitatif mengenai performa model, terutama pada data yang tidak seimbang.

a. *Classification Report*

Classification Report digunakan untuk evaluasi kinerja model juga dilakukan dengan menggunakan *classification report* yang memiliki sejumlah metrik utama untuk menilai kualitas klasifikasi pada setiap kelas. Evaluasi ini mencakup nilai *precision*, *recall*, dan F1-score.

1) Precision

Precision adalah metrik evaluasi yang digunakan untuk mengukur ketepatan model dalam mengklasifikasikan berita hoaks secara benar. Nilai *precision* menunjukkan seberapa banyak dari prediksi hoaks yang memang benar-benar hoaks. Kategori ini disebut sebagai *true positive* (TP). Sementara itu, jika model salah mengklasifikasikan berita non-hoaks sebagai hoaks, hasilnya disebut *false positive* (FP). Semakin tinggi presisi, semakin kecil kemungkinan model melakukan kesalahan dalam menandai berita non-hoaks sebagai hoaks. *Precision* penting untuk memastikan sistem tidak memberikan alarm palsu terhadap informasi yang benar. *Precision* dapat dirumuskan dengan persamaan 3.8.

$$P = \frac{TP}{TP + FP} \quad (3.8)$$

Keterangan:

- P* (Precision) : perbandingan antara TP (berita hoaks klasifikasi hoaks) dengan banyaknya data yang klasifikasikan sebagai hoaks
- TP* : model mengklasifikasikan data sebagai hoaks dan memang data seharusnya ada di kelas hoaks
- FP* : model mengklasifikasikan data yang ada di kelas hoaks, namun seharusnya data ada di kelas non-hoaks.

Dengan kata lain, *precision* merupakan rasio antara jumlah berita hoaks yang berhasil dideteksi dengan benar oleh model (TP) dan total berita yang diklasifikasikan sebagai hoaks oleh model (TP + FP). Nilai *precision* yang tinggi menunjukkan bahwa model memiliki tingkat akurasi yang baik dalam mengenali berita hoaks serta menghasilkan sedikit kesalahan klasifikasi terhadap berita non-hoaks. Namun demikian, *precision* saja tidak cukup untuk mengevaluasi performa keseluruhan model, karena tidak mempertimbangkan kasus ketika berita hoaks justru tidak terdeteksi dan diklasifikasikan sebagai non-hoaks (FN). Oleh karena itu, *precision* umumnya digunakan bersama metrik evaluasi lainnya untuk memberikan gambaran yang lebih menyeluruh tentang kinerja model

2) Recall

Recall adalah ukuran yang menunjukkan sejauh mana model dapat mendeteksi semua berita hoaks yang ada didalam dataset. Dalam penelitian ini, berita hoaks yang benar-benar dideteksi oleh model sebagai berita hoaks adalah *true positive* (TP), sedangkan berita hoaks yang tidak terdeteksi oleh model adalah

berita hoaks yang diklasifikasi non-hoaks atau *false negative* (FN). *Recall* dapat dirumuskan pada persamaan 3.9.

$$r = \frac{TP}{TP + FN} \quad (3.9)$$

Keterangan:

- r (recall)* : Perbandingan antara TP (berita hoaks klasifikasi hoaks) dengan banyaknya data yang sebenarnya adalah berita hoaks
TP : Model mengklasifikasikan data di kelas hoaks dan yang seharusnya ada di kelas hoaks
FN : Model mengklasifikasikan data yang berada di kelas non-hoaks, namun seharusnya data ada di kelas hoaks.

Dengan kata lain, *recall* merupakan perbandingan antara jumlah berita hoaks yang berhasil dikenali dengan benar oleh model (TP) dan total keseluruhan berita hoaks yang terdapat dalam dataset. Semakin tinggi nilai *recall*, semakin baik kemampuan model dalam mendeteksi berita hoaks secara menyeluruh, serta semakin sedikit kasus berita hoaks yang terlewat atau tidak teridentifikasi.

3) *F1-Score*

F1-Score merupakan metrik evaluasi yang menggabungkan nilai *precision* dan *recall* ke dalam satu ukuran tunggal, yaitu rata-rata harmonik dari keduanya. Metrik ini memberikan penilaian yang lebih seimbang terhadap kinerja model secara keseluruhan, terutama saat terdapat ketidakseimbangan antara *precision* dan *recall*. Oleh karena itu, *F1-Score* sering digunakan untuk memperoleh gambaran yang lebih menyeluruh dibandingkan jika hanya menggunakan salah satu metrik saja. Rumus perhitungannya ditunjukkan pada persamaan 3.10.

$$f1 = \frac{2 * recall * precision}{recall + precision} \quad (3.10)$$

Keterangan:

F1 (f1-score) : Perbandingan rata-rata *precision* dan *recall* yang dibobotkan
recall : Perbandingan antara TP (berita hoaks yang diklasifikasi hoaks) dengan banyaknya data yang sebenarnya hoaks
precision : Perbandingan antara TP (berita hoaks yang diklasifikasi hoaks) dengan banyaknya data yang diklasifikasikan sebagai berita hoaks

Dengan kata lain *F1-Score* adalah rata-rata *harmonic* dari *precision* dan *recall*. Nilai *F1-Score* sangat berguna dalam situasi di mana kita ingin mencari keseimbangan antara *precision* dan *recall* dan tidak ada lebih penting dari pada yang lain. dalam penelitian ini, peneliti ingin model memiliki *precision* yang baik (meminimalkan hoaks sebagai non-hoaks) dan *recall* yang baik (meminimalkan non-hoaks sebagai hoaks). Oleh karena itu *F1-Score* adalah matriks yang baik untuk mengevaluasi kinerja model dalam penelitian ini (Shishah, 2022).

b. Confusion Matrix

Confusion matrix merupakan sebuah matriks yang digunakan untuk mengevaluasi hasil prediksi model dengan membandingkannya terhadap label sebenarnya. Matriks ini terdiri atas empat bagian. Yang pertama adalah bagian jumlah data berita hoaks yang diklasifikasikan dengan benar sebagai berita hoaks (TP), yang kedua, bagian jumlah data non-hoaks yang salah diklasifikasikan sebagai hoaks (FP), yang ketiga, jumlah data hoaks yang salah diklasifikasikan sebagai non-hoaks (FN), yang keempat adalah jumlah data non-hoaks yang diklasifikasikan dengan benar sebagai non-hoaks (TN), Melalui *confusion matrix*, dapat dianalisis pola kesalahan model serta kemampuan dalam mengklasifikasikan

antara kelas mayoritas (non-hoaks) dan minoritas (hokas). *confusion matrik* untuk klasifikasi berita hoaks dapat dilihat pada gambar 3.7.

		Data Actual	
		Hoaks	Non-hoaks
Klasifikasi	Hoaks	TP (True Positive) Jumlah berita Hoaks diklasifikasikan sebagai hoaks	FP (True Positive) Jumlah berita Non-hoaks diklasifikasikan sebagai hoaks
	Non-hoaks	FN (False Negative) Jumlah berita Hoaks diklasifikasikan sebagai non-hoaks	TN (True Negative) Jumlah berita Non-hoaks diklasifikasika sebagai non-hoaks

Gambar 3.7. *Confusion Matrics* untuk klasifikasi berita hoaks

BAB IV

METODE FOCAL LOSS

4.1. Perhitungan

Penelitian ini menggunakan dataset yang memiliki distribusi kelas yang tidak seimbang, di mana sebanyak 80% merupakan berita non-hoaks dan hanya 20% merupakan berita hoaks. Ketidakseimbangan ini dapat menimbulkan bias pada model pembelajaran, khususnya dalam mengenali kelas minoritas, sehingga performa klasifikasi terhadap berita hoaks menjadi kurang optimal. Untuk mengatasi permasalahan tersebut, digunakan *focal loss* sebagai *loss function*. *Focal loss* dirancang untuk memberikan bobot yang lebih besar pada sampel yang sulit diklasifikasikan, yaitu kelas dengan jumlah data yang lebih sedikit, serta mengurangi kontribusi dari sampel yang mudah diklasifikasikan. Sehingga pendekatan dapat membantu model untuk lebih memperhatikan dan mempelajari karakteristik kelas minoritas. Rumus *focal loss* dapat dilihat pada persamaan 4.1.

$$FL = -a_t(1 - p_t)^\gamma \log(p_t) \quad (4.1)$$

Keterangan:

- p_t : probabilitas prediksi untuk kelas yang benar
- γ : focus parameter
- a_t : balancing factor antara kelas

Dengan menggunakan rumus tersebut, maka dapat dilakukan perhitungan manual.

- a. Contoh kelas hoaks

Label = 1 (berita hoaks)

Prediksi model (p) = 0.3, model cukup yakin ini bukan hoaks (salah prediksi)

$$p_t = p = 0.3$$

$$a_t = 0.75$$

$$\gamma = 2$$

Perhitungan manual

$$\begin{aligned} &= -0,75(1 - 0,3)^2 \cdot \log(0,3) \\ &= -0,75(0,7)^2 \cdot (1,204) \\ &= -0,75 \cdot 0,49 \cdot 1,204 = 0,443 \end{aligned}$$

Hasil Focal Loss = 0,443 (besar karena prediksi salah dan kelas minoritas)

b. Contoh kelas non-hoaks

Label = 0 (berita non-hoaks)

Prediksi model (p) = 0.2 (model cukup yakin ini berita hoaks)

$$p_t = 1 - p = 1 - 0,2 = 0,8$$

$$a_t = 0,25$$

$$\gamma = 2$$

Perhitungan manual

$$\begin{aligned} &= -0,25(1 - 0,8)^2 \cdot \log(0,8) \\ &= -0,75(0,2)^2 \cdot (0,223) \\ &= -0,75 \cdot 0,04 \cdot 0,223 = 0,00223 \end{aligned}$$

Hasil focal loss = 0,00223 (sangat kecil karena kelas mayoritas)

4.2. Pengujian

Proses pelatihan model dengan menerapkan *focal loss* dilakukan melalui dua skema percobaan yang berbeda. Pada percobaan pertama, data dibagi dengan proporsi 70:15:15, yaitu 70% dari keseluruhan data digunakan sebagai data pelatihan, 15% sebagai data validasi, dan 15% sisanya sebagai data pengujian. Sementara itu, pada percobaan kedua, pembagian data dilakukan dengan proporsi

80:10:10, di mana 80% dialokasikan untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Tujuan dari kedua skema ini adalah untuk mengevaluasi pengaruh perbedaan pembagian data terhadap kinerja model klasifikasi yang dilatih menggunakan *focal loss*. Kedua percobaan dilakukan dengan sejumlah parameter, yaitu *batch size* sebesar 32, *learning rate* sebesar $2e-5$, jumlah *epoch* sebanyak 15, dan menggunakan *optimizer AdamW*. Pada model *Focal Loss* diterapkan nilai alpha 0,25 dan 0,75 serta parameter gamma sebesar 2.0.

a. Percobaan pertama (split data 70:15:15)

Hasil evaluasi performa model klasifikasi dengan menerapkan pendekatan *focal loss* pada skema pembagian data sebesar 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian, menunjukkan performa yang baik. Model *focal loss* mencapai nilai akurasi sebesar 0.958, menandakan bahwa sebagian besar hasil klasifikasi model terhadap data uji sudah sesuai dengan label sebenarnya. Pada kelas hoaks yang merupakan kelas minoritas, model menghasilkan nilai *precision* sebesar 0.907, *recall* sebesar 0.882, dan *f1-score* sebesar 0.894. Tabel hasil *classification report* dapat dilihat pada tabel 4.1

Tabel 4.1. Hasil pengujian dengan split data 70:15:15

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>
Hoaks	0.907	0.882	0.894	0.958

Selain menggunakan *classification report* untuk evaluasi, peneliti juga menampilkan *Confusion matrix* untuk memudahkan analisa, *Confusion matrix* digunakan untuk mengevaluasi secara detail kemampuan *focal loss* dalam mengklasifikasikan data, dengan menunjukan jumlah data yang diklasifikasikan

dengan benar dan jumlah data yang diklasifikasikan pada kelas yang salah. Hasil evaluasi dengan *confusion matrix* ditunjukkan pada gambar 4.1

		Label sebenarnya	
		Hoaks	Non-hoaks
Hasil klasifikasi	Hoaks	98	10
	Non-hoaks	13	434

Gambar 4.13 *Confusion matrix focal loss* dengan split data 70:15:15

Berdasarkan matriks tersebut, dari total 444 sampel berita non-hoaks, sebanyak 434 diklasifikasikan dengan benar, sementara 10 sampel salah diprediksi sebagai hoaks. Untuk kelas hoaks, dari 111 sampel, sebanyak 98 berhasil diklasifikasikan dengan benar, dan 13 sisanya salah diklasifikasikan sebagai fakta. Hasil ini menunjukkan bahwa model memiliki tingkat akurasi yang tinggi, serta mampu mengenali kedua kelas dengan baik, termasuk kelas minoritas (hoaks). pada metrik *F1-score*, model mencatatkan nilai *F1-score* sebesar 0,974 untuk kelas non-hoaks dan 0,895 untuk kelas hoaks. Hal ini menunjukkan bahwa *Focal Loss* mampu menjaga performa tinggi dalam mengidentifikasi berita non-hoaks, sekaligus secara signifikan meningkatkan kemampuan model dalam mengenali berita hoaks, yang sebelumnya merupakan kelas minoritas dengan tingkat kesalahan lebih tinggi. Nilai rata-rata *F1-score (macro average)* yang diperoleh adalah 0,934, meningkat dari sebelumnya yang hanya 0,919. Peningkatan ini mengindikasikan bahwa *Focal Loss* efektif dalam mengatasi ketidakseimbangan data, dengan memberikan perhatian

lebih pada data yang sulit diklasifikasikan, seperti berita Hoaks, sehingga model menjadi lebih seimbang dalam performanya terhadap kedua kelas.

b. Percobaan kedua (split data 80:10:10)

Hasil evaluasi performa model klasifikasi dengan menerapkan pendekatan *focal loss* pada skema pembagian data sebesar 80% untuk data pelatihan, 10% untuk data validasi, dan 10% data pengujian, menunjukkan performa yang lebih baik dari. Model mencapai nilai akurasi sebesar 0.973, hasil tersebut menandakan bahwa sebagian besar klasifikasi model terhadap data uji sesuai dengan label sebenarnya. Pada kelas hoaks yang merupakan kelas minoritas, model menghasilkan nilai *precision* sebesar 0.957, *recall* sebesar 0.905, dan *f1-score* sebesar 0.930. Hasil *classification report* dapat dilihat pada tabel 4.2

Tabel 4.2. Hasil pengujian dengan split data 80:10:10

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Accuracy
Hoaks	0.957	0.905	0.930	0.973

Selain menggunakan *classification report* peneliti juga menampilkan evaluasi dalam *Confusion matrix* untuk memudahkan analisa. *Confusion matrix* digunakan untuk mengevaluasi secara detail kemampuan model dalam mengklasifikasikan setiap kelas. Hasil evaluasi *confusion matrix* ditunjukkan pada gambar 4.2

		Label sebenarnya	
		Hoaks	Non-hoaks
Hasil klasifikasi	Hoaks	67	3
	Non-hoaks	7	293

Gambar 4.2. *Confusion matrix focal loss* dengan split data 80:10:10

Berdasarkan matriks tersebut, dari total 296 sampel berita non-hoaks, sebanyak 293 diklasifikasikan dengan benar, sementara 3 sampel salah diprediksi sebagai hoaks. Untuk kelas hoaks, dari 74 sampel, sebanyak 67 berhasil diklasifikasikan dengan benar, dan 7 sisanya salah diklasifikasikan sebagai fakta. Hasil ini menghasilkan nilai *precision* untuk kelas hoaks sebesar 0,957 dan *recall* sebesar 0,905. Dengan demikian, *F1-score* untuk kelas hoaks mencapai 0,930. Nilai *F1-score* yang tinggi ini menunjukkan penerapan *focal loss* efektif dalam mengatasi ketidakseimbangan data, dengan meningkatkan sensitivitas model terhadap kelas minoritas (hoaks) tanpa mengorbankan akurasi pada kelas mayoritas (non-hoaks).

4.3. Analisis Hasil

Pada penelitian ini, dilakukan pengujian klasifikasi berita hoaks berbahasa Indonesia menggunakan model IndoBERT yang telah dilakukan *fine-tuning*, serta penerapan *Focal Loss* sebagai fungsi kerugian untuk menangani ketidakseimbangan data antar kelas. Evaluasi dilakukan pada dua skenario pembagian data, yakni 70:15:15 dan 80:10:10 untuk data latih, validasi, dan uji. Pada skenario pertama, hasil evaluasi classification report yang ditunjukkan tabel 4.1

dan hasil *confusion matrik* pada gambar 4.1 menunjukkan model memperoleh akurasi sebesar 95,8%. Meskipun begitu nilai *precision*, *recall* dan *F1-score* yang lebih rendah pada kelas hoaks menunjukkan bahwa meskipun *focal loss* membantu menangani ketidakseimbangan, performa terhadap kelas minoritas masih belum optimal dalam skenario ini. Hal ini diduga karena jumlah data pelatihan yang lebih sedikit, sehingga pelatihan pola kelas hoaks masih terbatas.

Pada skenario kedua, sesuai hasil evaluasi *classification report* yang ditunjukkan pada tabel 4.2 dan hasil *confusion matrik* pada gambar 4.2 menunjukkan peningkatan kinerja secara keseluruhan dengan akurasi sebesar 97,3%. Peningkatan kinerja ini menunjukkan bahwa dengan proporsi data pelatihan yang lebih besar (80%), model lebih mampu mempelajari representasi dari data, termasuk dalam mengidentifikasi berita hoaks yang merupakan kelas minoritas. Nilai *F1-score* pada kelas hoaks yang lebih tinggi juga menandakan bahwa model berhasil menjaga keseimbangan antara *precision* dan *recall* dengan baik.

Jika dibandingkan antara kedua skenario, terlihat bahwa skenario kedua memberikan hasil klasifikasi yang lebih baik. Hal ini dapat dilihat dari peningkatan seluruh metrik evaluasi, terutama pada kelas hoaks. Penggunaan *focal loss* pada kedua skenario berhasil meminimalkan dominasi kelas mayoritas (non-hoaks), namun efeknya lebih optimal ketika didukung oleh jumlah data pelatihan yang lebih besar. Dengan demikian, dapat disimpulkan bahwa proporsi data pelatihan yang lebih besar berkontribusi signifikan terhadap peningkatan kinerja model, baik dalam hal akurasi keseluruhan maupun kemampuan klasifikasi terhadap kelas minoritas

BAB V

METODE CROSS ENTROPY

5.1. Perhitungan

Dalam penelitian ini, metode *Cross Entropy* digunakan sebagai pembandingan terhadap metode *Focal Loss* dalam mengatasi permasalahan ketidakseimbangan data. Tujuan penggunaan *cross entropy* adalah untuk melihat perbandingan kinerjanya dengan *focal loss* yang secara khusus dirancang untuk menghadapi ketidakseimbangan data. Dataset yang digunakan pada eksperimen *cross entropy* sama dengan dataset yang digunakan pada *focal loss*, yakni terdiri dari 80% data berita non-hoaks dan 20% data berita hoaks. Dengan menggunakan dataset yang identik, perbandingan performa kedua metode dapat dilakukan secara adil dan objektif. Rumus *cross entropy* yang dapat dilihat pada persamaan 5.1.

$$CE = -(y \cdot \log(p) + (1 - y) \cdot \log(1 - p)) \quad (5.1)$$

Keterangan:

y : label sebenarnya, bernilai 0 dan 1
 p : Probabilitas yang di prediksi model (nilai antara 0 sampai 1)
 $\log(p)$: logaritma natural

Untuk kemudahan notasi, persamaan 5.1 bisa disederhanakan menjadi seperti persamaan 5.2.

$$CE(p_t) = -\log(p_t) \quad (5.2)$$

Dengan $P_t = \begin{cases} p & \text{jika } y = 1 \\ 1 - p & \text{jika } y = 0 \end{cases}$

a. Contoh perhitungan kelas hoaks

Jika $y = 1$, dan $p = 0,9$

$$CE = -\log(0,9) \\ = 0.10536$$

Loss = 0.10536 (kecil karena prediksi mendekati label sebenarnya)

b. Contoh lain (prediksi salah)

Jika $y = 0$, dan $p = 0,9$

$$CE = -\log(1 - 0,9) \\ = -\log(0,1) \\ = 2,3026$$

Loss = 2.3026 (besar karena prediksi sangat jauh dari sebenarnya)

5.2. Pengujian

Proses pelatihan model dengan menerapkan *cross entropy* dilakukan melalui dua skema percobaan yang berbeda. Pada percobaan pertama, data dibagi dengan proporsi 70:15:15, yaitu 70% dari keseluruhan data digunakan sebagai data pelatihan, 15% sebagai data validasi, dan 15% sisanya sebagai data pengujian. Sementara itu, pada percobaan kedua, pembagian data dilakukan dengan proporsi 80:10:10, di mana 80% dialokasikan untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Tujuan dari kedua skema ini adalah untuk mengevaluasi pengaruh perbedaan pembagian data terhadap kinerja model klasifikasi yang dilatih menggunakan *cross entropy*. Kedua percobaan dilakukan dengan sejumlah parameter, yaitu *batch size* sebesar 32, *learning rate* sebesar $2e-5$, jumlah *epoch* sebanyak 15, dan menggunakan *optimizer AdamW*.

a. Percobaan pertama (split data 70:15:15)

Hasil evaluasi performa model klasifikasi dengan menerapkan *cross entropy* pada skema pembagian data sebesar 70% data pelatihan, 15% data validasi, dan

15% data pengujian, menunjukkan performa yang cukup baik. Model mencapai nilai akurasi sebesar 0.951, menandakan bahwa sebagian besar klasifikasi model terhadap data uji sesuai dengan label sebenarnya. Pada kelas hoaks yang merupakan kelas minoritas dengan proporsi data 20%, model *cross entropy* menghasilkan nilai *precision* sebesar 0.946, *recall* sebesar 0.801, dan *f1-score* sebesar 0.868. hasil evaluasi *classification report* dapat dilihat pada tabel 5.1

Tabel 5.1. Hasil pengujian dengan split data 70:15:15

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>
Hoaks	0.946	0.801	0.868	0.951

Selain menggunakan *classification report* untuk evaluasi, peneliti juga menampilkan evaluasi dengan *Confusion matrix* untuk memudahkan dalam analisa, *Confusion matrix* digunakan untuk mengevaluasi secara detail kemampuan model *focal loss* dalam mengklasifikasikan data pada setiap kelas, dengan cara menunjukkan jumlah data yang diklasifikasikan dengan benar dan jumlah data yang diklasifikasikan pada kelas yang salah. Hasil evaluasi dengan *confusion matrix* ditunjukkan pada gambar 5.1

		Label sebenarnya	
		Hoaks	Non-hoaks
Hasil klasifikasi	Hoaks	89	9
	Non-hoaks	22	439

Gambar 5.15 *Confusion matrix cross entropy* dengan split data 70:15:15

Berdasarkan matriks tersebut, dari total 444 sampel berita non-hoaks, sebanyak 439 diklasifikasikan dengan benar, sementara 5 sampel salah diprediksi sebagai hoaks. Untuk kelas hoaks, dari 111 sampel, sebanyak 89 berhasil diklasifikasikan dengan benar, dan 22 sisanya salah diklasifikasikan sebagai fakta. Hasil ini menunjukkan bahwa model bagus dan akurat dalam mengklasifikasikan data mayoritas (non-hoaks) tetapi kurang akurat dalam mengklasifikasikan data minoritas (berita hoaks) terbukti terdapat banyak data hoaks yang diklasifikasikan sebagai fakta.

Nilai *F1 score* untuk kelas non-hoaks mencapai 0,970, yang menunjukkan keseimbangan cukup baik antara *precision* (0,952) dan *recall* (0,989). Artinya, model mampu mengenali berita non-fakta dengan cukup baik, baik dalam hal mengurangi kesalahan klasifikasi maupun dalam mendeteksi berita non-fakta secara konsisten. Di sisi lain, *F1-score* untuk kelas hoaks adalah 0,868, yang meskipun cukup tinggi, namun menunjukkan bahwa performa model belum optimal dalam mengenali berita Hoaks. Hal ini tampak dari nilai *recall* untuk kelas hoaks yang hanya sebesar 0,802, menandakan masih ada cukup banyak berita hoaks yang tidak terdeteksi oleh model.

b. Percobaan kedua (split data 80:10:10)

Hasil evaluasi performa model klasifikasi dengan menerapkan pendekatan *cross entropy* pada skema pembagian data sebesar 80% data pelatihan, 10% data validasi, dan 10% data pengujian, menunjukkan performa yang menurun dari skenario pertama. Model mencapai nilai akurasi sebesar 0.962, menandakan bahwa sebagian besar prediksi model terhadap data uji sesuai dengan label sebenarnya.

Pada kelas hoaks yang merupakan kelas minoritas dengan proporsi data 20%, model menghasilkan nilai *precision* sebesar 0.928, *recall* sebesar 0.878, dan *f1-score* sebesar 0.902. Hasil *classification report* dapat dilihat pada tabel 5.2

Tabel 5.2 Hasil pengujian dengan split data 80:10:10

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Accuracy
Hoaks	0.928	0.878	0.902	0.962

Selain menggunakan *classification report* untuk evaluasi, peneliti juga menampilkan *Confusion matrix* untuk memudahkan dalam analisa, *Confusion matrix* digunakan untuk mengevaluasi secara detail kemampuan model *focal loss* dalam mengklasifikasikan data, dengan menunjukkan jumlah data yang diklasifikasikan dengan benar dan jumlah data yang diklasifikasikan pada kelas yang salah. Hasil evaluasi dengan *confusion matrix* ditunjukkan pada gambar 5.2.

		Label sebenarnya	
		Hoaks	Non-hoaks
Hasil klasifikasi	Hoaks	65	5
	Non-hoaks	9	291

Gambar 5.2. *Confusion matrix Cross Entropy* dengan split data 80:10:10

Berdasarkan metrik tersebut, dari total 296 sampel berita non-hoaks, sebanyak 291 diklasifikasikan dengan benar, sementara 5 sampel salah diprediksi sebagai hoaks. Untuk kelas hoaks, dari 74 sampel, sebanyak 65 berhasil diklasifikasikan dengan benar, 9 sisanya salah diklasifikasikan sebagai non-hoaks.

Nilai *F1-score* untuk kelas hoaks sebesar 0,903. Nilai ini menunjukkan bahwa model mampu mengklasifikasikan berita hoaks dengan cukup baik, meskipun masih terdapat beberapa kesalahan dalam prediksi. Jika dibandingkan dengan pendekatan Focal Loss yang menghasilkan *F1-score* sebesar 0,930, terlihat bahwa *Cross Entropy* menghasilkan performa yang sedikit lebih rendah dalam mendeteksi kelas hoaks. Dengan demikian, *F1-score* dari *Cross Entropy Loss* menunjukkan performa yang baik, namun masih kalah unggul dibandingkan *Focal Loss* dalam konteks klasifikasi berita hoaks.

5.3. Analisis Hasil

Sebagai pembandingan terhadap pendekatan *Focal Loss*, dilakukan pula pelatihan dan evaluasi model IndoBERT dengan fungsi *loss* standar yaitu *Cross Entropy Loss*, yang umum digunakan dalam tugas klasifikasi. Sama seperti sebelumnya, dua skenario pembagian data diuji, yakni 70:15:15 dan 80:10:10. Hasil evaluasi *classification report* yang ditunjukkan pada tabel 5.1 dan hasil evaluasi *confusion matrix* yang ditunjukkan gambar 5.1. menunjukkan perbandingan antara kedua skenario dengan *Cross Entropy Loss* bahwa pola yang serupa dengan eksperimen *Focal Loss*, yaitu bahwa penambahan data latih berdampak langsung terhadap peningkatan *recall* dan *F1-score* pada kelas hoaks. Hal ini penting mengingat hoaks merupakan kelas minoritas, dan *recall* menjadi metrik yang krusial dalam mengukur keberhasilan deteksi kasus positif.

Namun, dibandingkan dengan hasil *Focal Loss* pada skenario yang sama, *Cross Entropy* masih menghasilkan *recall* dan *F1-score* yang lebih rendah pada kelas hoaks, meskipun akurasinya secara umum mirip. Ini menunjukkan bahwa

Cross Entropy masih cenderung bias terhadap kelas mayoritas (non-hoaks), sehingga performa terhadap kelas minoritas (hoaks) kurang optimal, khususnya ketika jumlah data pelatihan lebih terbatas seperti pada skenario 70:15:15.

BAB VI

PEMBAHASAN

6.1. Analisis Kinerja IndoBERT

Penelitian ini bertujuan untuk membantu mengurangi penyebaran berita hoaks di media daring, mengingat banyaknya informasi yang beredar secara bebas di media daring menciptakan tantangan dalam membedakan antara berita yang non-hoaks dan yang hoaks. Dalam perspektif Islam, adanya perbedaan informasi ditegaskan dalam Al-Qur'an, Surah Ali 'Imran ayat 7, yang mengelompokkan ayat-ayat menjadi dua jenis, yaitu ayat Muhkamat, yakni ayat yang maknanya jelas dan tidak menimbulkan keraguan, dan yang kedua adalah ayat Mutasyabihat, yaitu ayat yang mengandung makna yang samar atau multitafsir. Analogi ini dapat dijadikan landasan normatif dalam membedakan antara informasi yang non-hoaks dan hoaks dalam konteks digital masa kini. Firman Allah dalam Surah Ali Imron ayat 7.

هُوَ الَّذِي أَنْزَلَ عَلَيْكَ الْكِتَابَ مِنْهُ آيَاتٌ مُحْكَمَاتٌ هُنَّ أُمُّ الْكِتَابِ وَأُخْرُ مُتَشَابِهَاتٌ ۚ
فَأَمَّا الَّذِينَ فِي قُلُوبِهِمْ زَيْغٌ فَيَتَّبِعُونَ مَا تَشَابَهَ مِنْهُ ابْتِغَاءَ الْفِتْنَةِ وَابْتِغَاءَ تَأْوِيلِهِ ۗ وَمَا يَعْلَمُ
تَأْوِيلَهُ إِلَّا اللَّهُ وَالرَّسِخُونَ فِي الْعِلْمِ يَقُولُونَ آمَنَّا بِهِ كُلٌّ مِنْ عِنْدِ رَبِّنَا ۗ وَمَا يَذَّكَّرُ إِلَّا أُولُو
الْأَلْبَابِ — ال عمران : ٧

Artinya: Dialah yang menurunkan Kitab (Al-Qur'an) kepadamu (Muhammad). Di antaranya ada ayat-ayat yang muhkamat, itulah pokok-pokok Kitab (Al-Qur'an) dan yang lain mutasyabihat. Adapun orang-orang yang dalam hatinya condong pada kesesatan, mereka mengikuti yang mutasyabihat untuk mencari-cari fitnah dan untuk mencari-cari takwilnya, padahal tidak ada yang mengetahui takwilnya kecuali Allah. Dan orang-orang yang ilmunya mendalam berkata, "Kami beriman kepadanya (Al-Qur'an), semuanya dari sisi Tuhan kami." Tidak ada yang dapat mengambil pelajaran kecuali orang yang berakal (QS: Ali-Imron : 7).

Dalam terjemahan Tafsir Ibnu Katsir disampaikan bahwa “Allah *Subhanahu Wata’ala* memberitahukan bahwa di dalam Al-Qur’an terdapat ayat-ayat *muhkamat* (jamak dari *muhkam*) yang semuanya merupakan pokok-pokok Al-Qur’an. Yaitu ayat-ayat yang jelas dan terang pengertiannya, yang tidak ada kesamaran bagi siapapun. Selain itu ada ayat-ayat lainnya, yaitu ayat *mutasyabihat* (jamak dari *mutasyabih*), yaitu ayat-ayat yang didalamnya terdapat kesamaran pengertian bagi kebanyakan atau sebagian orang. Maka barangsiapa mengembalikan yang samar itu kepada yang jelas dari Al-Qur’an, berarti dia telah mendapatkan petunjuk. Dan barangsiapa melakukan hal yang sebaliknya, maka diapun akan memetik akibat yang sebaliknya. Oleh karena itu Allah berfirman itulah pokok-pokok isi Al-Qur’an, yaitu pokok yang menjadi rujukan Ketika menemukan kesamaran” (Ibnu Katsir, 2003, hlm 5)

Informasi berita juga diklasifikasikan menjadi dua jenis, yaitu hoaks dan non-hoaks. Untuk memastikan apakah suatu informasi termasuk hoaks atau non-hoaks, perlu dilakukan pencarian rujukan dengan berita non-hoaks yang telah terbukti kebenarannya, agar masyarakat tidak terjebak dalam informasi yang menyesatkan. Penelitian mengenai klasifikasi berita hoaks dalam Bahasa Indonesia dapat membantu masyarakat membedakan antara informasi yang dapat dipercaya (non-hoaks) dan informasi yang tidak dapat dipercaya (hoaks).

Dalam penelitian ini, model IndoBERT digunakan sebagai inti dari sistem klasifikasi berita hoaks berbahasa Indonesia. Pemilihan IndoBERT dilandaskan pada karakteristik arsitektur *Transformer*-nya yang telah diadaptasi secara khusus terhadap bahasa Indonesia. Model IndoBERT memiliki konsep *pre-training* dan *fine-tuning*. *Pre-training* bertugas melatih model pada data besar dan umum agar memahami pola bahasa secara umum sedangkan *fine-tuning* bertugas menyesuaikan model tersebut pada tugas atau domain khusus. Dalam penelitian ini Proses *fine-tuning* terhadap IndoBERT dilakukan pada data yang terdiri dari 3.695 data, dengan proporsi kelas tidak seimbang, yaitu 20% berita hoaks dan 80% berita

non-hoaks. *Fine-tuning* dilaksanakan dengan 15 *epoch* dengan parameter *batch size* sebesar 32 dan *learning rate* $2e-5$. Tujuan dari proses ini adalah untuk mengadaptasi parameter model agar mampu mengenali pola-pola linguistik yang berkaitan dengan konten hoaks secara lebih spesifik dalam konteks bahasa Indonesia. Secara umum, hasil eksperimen menunjukkan bahwa IndoBERT mampu memberikan performa klasifikasi yang sangat baik. Hal ini mencerminkan bahwa arsitektur dari *pre-training* yang digunakan dalam IndoBERT telah memberikan fondasi representasi bahasa yang kuat, sehingga mampu menangkap perbedaan halus antara berita non-hoaks dan berita hoaks.

Konsep *pre-training* dan *fine tuning* yang dimiliki oleh IndoBERT tersebut dapat dianalogikan dengan konsep pendidikan yang bertahap dalam islam, Nabi Muhammad *Sallallahu 'Alaihi Wasallam* menerima wahyu melalui proses pembinaan yang bertahap, pada surah Makkiyah yaitu surah yang diturunkan di Mekah sebelum Nabi Muhammad *Sallallahu 'Alaihi Wasallam* hijrah ke Madinah yang lebih banyak berisi tentang membangun pondasi tauhid. Sedangkan surah Madaniyah lebih banyak membahas yang lebih spesifik tentang syari'at dan tata cara sosial. Ini mencerminkan strategi *pre-training* (Makkiyah) untuk pembentukan pondasi, dan *fine-tuning* (Madaniyah) sebagai penyesuaian praktis dalam masyarakat. Model IndoBERT juga berfungsi baik karena telah melalui dua fase pembelajaran seperti ini. Pentingnya proses pendidikan secara bertahap lebih spesifik dijelaskan dalam surah Al-Furqon ayat 32. Allah *Subhanahu Wata'ala* berfirman :

وَقَالَ الَّذِينَ كَفَرُوا لَوْلَا نُزِّلَ عَلَيْهِ الْقُرْآنُ جُمْلَةً وَّاحِدَةً كَذَلِكَ لِنُثَبِّتَ بِهِ فُؤَادَكَ
وَرَتَّلْنَاهُ تَرْتِيلًا - الفرقان - ٣٢

Artinya: Orang-orang yang kufur berkata, “Mengapa Al-Qur’an itu tidak diturunkan kepadanya sekaligus?” Demikianlah, agar Kami memperteguh hatimu (Nabi Muhammad) dengannya dan Kami membacakannya secara tartil (berangsur-angsur, perlahan, dan benar).

Dalam tafsir Kementerian Agama Republik Indonesia dijelaskan “Pada ayat berikut diceritakan lagi permintaan lainnya yang mengada-ada yang dikemukakan oleh orang kafir kepada Nabi Muhammad. Dan orang-orang kafir berkata, “Mengapa Al-Qur’an itu tidak diturunkan kepadanya sekaligus sebagaimana kitab-kitab samawi dulu seperti kitab Taurat, Zabur, dan Injil, bukan berangsur-angsur sebagaimana Al-Qur’an?” Demikianlah, Kami turunkan Al-Qur’an secara berangsur-angsur agar Kami memperteguh hatimu Muhammad dengannya karena setiap kali ayat Al-Qur’an turun, nabi merasa tenang karena Allah selalu menyertainya dalam suka maupun duka dan Kami membacakannya secara tartil berangsur-angsur, perlahan dan benar, selama kurang lebih 23 tahun. Membaca Al-Qur’an dengan tartil, sangat di dianjurkan. Diturunkannya Al-Qur’an secara berangsur, agar mudah dihafal, dihayati, dan diamalkan sedikit demi sedikit.” (Kementerian Agama Republik Indonesia, 2019, Al-Furqon: 32)

Ayat ini menjelaskan hikmah kenapa Al-Qur’an tidak diturunkan sekaligus, agar proses belajar menjadi lebih baik dan efektif. Dalam konteks *machine learning*, dalam penelitian ini digunakan model IndoBERT yang memiliki tahapan *pre-training* dan *fine-tuning*. Pada tahap *pre-training* model memberikan pembelajaran dasar yang umum (seperti wahyu secara global), sementara tahap *fine-tuning* adalah penyesuaian sesuai dengan konteks (masalah tertentu) dalam penelitian ini adalah klasifikasi berita hoaks Bahasa Indonesia

6.2. Analisis hasil pendekatan focal loss

Focal Loss digunakan untuk mengatasi ketidakseimbangan distribusi data yang signifikan pada dataset. Fungsi *loss* ini dirancang untuk memfokuskan pelatihan model pada contoh-contoh yang sulit diklasifikasikan, seperti data dari

kelas minoritas (hoaks) yang jumlahnya jauh lebih sedikit dibandingkan kelas mayoritas (non-hoaks). Hasil evaluasi model dengan penerapan *Focal Loss* pada dua skema pembagian data menunjukkan bahwa skema kedua dengan pembagian data 80:10:10 memberikan kinerja yang lebih optimal dibandingkan dengan skema pertama 70:15:15. Hal ini mengindikasikan bahwa proporsi data pelatihan yang lebih besar pada skema 80:10:10 berkontribusi terhadap peningkatan kemampuan model dalam melakukan klasifikasi. Skema tersebut menunjukkan peningkatan performa yang signifikan, khususnya dalam mendeteksi kelas hoaks. Berdasarkan *classification report*, nilai *precision* mencapai 0,9571, *recall* sebesar 0,9054, dan *F1-score* sebesar 0,9306 untuk kelas hoaks. Hal ini mengindikasikan bahwa model tidak hanya akurat dalam mengidentifikasi hoaks, tetapi juga memiliki sensitivitas tinggi terhadap keberadaannya dalam data.

Evaluasi pada *confusion matrix* memperkuat hasil tersebut, di mana dari 74 data hoaks, 67 di antaranya diklasifikasikan dengan benar, dan hanya 7 yang salah diklasifikasikan. Sementara itu, untuk kelas non-hoaks, sebanyak 293 dari 296 data diklasifikasikan dengan benar, dan hanya 3 yang salah klasifikasi. Hasil ini menunjukkan bahwa model yang menggunakan pendekatan *focal loss* mampu meningkatkan kinerja klasifikasi pada kelas minoritas (hoaks) tanpa mengorbankan akurasi pada kelas mayoritas (non-hoaks). Selain itu, nilai akurasi keseluruhan mencapai 97,29%. Hasil ini menunjukkan bahwa penggunaan model dengan *focal loss* memiliki performa yang stabil di seluruh kelas dan sangat sesuai untuk diterapkan dalam konteks data yang tidak seimbang seperti kasus deteksi berita hoaks dalam penelitian ini.

Analogi pendekatan *focal loss* dalam perspektif Islam dapat kita temukan pada surah ‘Abasa ayat 1 sampai 10, pada ayat tersebut Allah *Subhanahu Wata’ala* menegur karena mengabaikan minoritas rentan, pada ayat tersebut Allah berfirman:

عَبَسَ وَتَوَلَّى (١), أَنْ جَاءَهُ الْأَعْمَى (٢), وَمَا يُدْرِيكَ لَعَلَّهٗ يَزْكَى (٣) أَوْ يَذَّكَّرُ فَتَنْفَعَهُ
الذِّكْرَى (٤) أَمَّا مَنْ اسْتَعْزَى (٥) فَأَنْتَ لَهُ تَصَدَّى (٦) وَمَا عَلَيْكَ إِلَّا يَرْكَى (٧) وَأَمَّا مَنْ
جَاءَكَ يَسْعَى (٨) وَهُوَ يَخْشَى (٩) فَأَنْتَ عَنْهُ تَلَهَّى (١٠)

Artinya: Dia (Nabi Muhammad) berwajah masam dan berpaling (1), karena seorang tunanetra (Abdullah bin Ummi Maktum) telah datang kepadanya.(2) Tahukah engkau (Nabi Muhammad) boleh jadi dia ingin menyucikan dirinya (dari dosa) (3). atau dia (ingin) mendapatkan pengajaran sehingga pengajaran itu bermanfaat baginya?(4), Adapun orang yang merasa dirinya serba cukup (para pembesar Quraisy) (5). engkau (Nabi Muhammad) memberi perhatian kepadanya.(6). Padahal, tidak ada (cela) atasmu kalau dia tidak menyucikan diri (beriman) (7). Adapun orang yang datang kepadamu dengan bersegera (untuk mendapatkan pengajaran) (8), sedangkan dia takut (kepada Allah) (9), malah engkau (Nabi Muhammad) abaikan (10) (QS. ‘Abasa ayat 1-10)

Dalam terjemahan Tafsir Ibnu Katsir dijelaskan “Lebih dari satu orang ahli tafsir yang menyebutkan bahwa pada suatu hari, Rosulullah *Shallallahu ‘Alaihi Wasallah* pernah berbicaradengan beberapa pembesar kaum Quraisy dan beliau berharap mereka mau memeluk Islam. Ketika beliau tengah berbicara dan mengaja mereka, tiba-tiba muncul Ibnu Ummi Maktum, di mana ia merupakan salah seorang yang memeluk Islam lebih awal, Maka Ibnu Ummi Maktum bertanya kepada Rosulullah *Shallallahu ‘Alaihi Wasallah* mengenai sesuatu seraya mendesak beliau. Dan Nabi sendiri berkeinginan andai saja waktu beliau itu cukup untuk berbicara dengan orang tersebut karena beliau memang sangat berharap dan berkeinginan untuk memberi petunjuk kepadanya. Dan beliau bermuka masam kepada Ibnu Ummi Maktum seraya berpaling darinya dan menghadap orang lain, maka turunlah firman Allah *Ta’ala* surah ‘Abasa ayat 1 sampai 10. Allah *Ta’ala* memerintahkan Rasul-nya agar tidak mengkhususkan pemberian peringatan itu hanya kepada seorang saja, tetapi hendaklah beliau bertindak sama, antara orang mulia, orang lemah, orang miskin, orang kaya, orang terhormat, hamba sahaya, laki-laki, perempuan, anak-anak dan orang dewasa. Kemudian Allah memberi petunjuk kepada siapa saja yang dia kehendaki ke jalan yang lurus. Dia lah yang memiliki hikmah yang memadai dan hujjah yang pasti.” (Ibnu Katsir, 2003, hlm. 397).

Dalam pendekatan pembelajaran mesin pada data yang tidak seimbang, metode *focal loss* digunakan untuk memberikan bobot lebih besar terhadap kelas

minoritas atau data yang sulit diklasifikasikan, tanpa mengabaikan kelas mayoritas. Pendekatan ini secara konseptual selaras dengan nilai-nilai keadilan dalam Islam, khususnya dalam peristiwa yang melatarbelakangi turunnya QS. 'Abasa (80): 1–10. Dalam ayat tersebut, Allah menegur Nabi Muhammad yang sempat berpaling dari Ibnu Ummi Maktum demi memperhatikan tokoh-tokoh Quraisy. Meskipun pendekatan Nabi bersifat strategis dalam dakwah, Allah *Subhanahu Wata'ala* mengingatkan bahwa memperhatikan individu yang tampak lemah namun bersungguh-sungguh dalam mencari kebenaran justru lebih bernilai di sisi-Nya.

Hal ini sejalan dengan prinsip *focal loss* yang tidak mendasarkan bobot semata-mata pada jumlah kemunculan data, tetapi pada tingkat kesulitannya. Dalam konteks klasifikasi berita hoaks yang memiliki ketimpangan kelas, seperti hoaks yang jarang namun berdampak tinggi jika salah diklasifikasikan, penerapan *focal loss* mencerminkan prinsip Islam dalam memberikan perhatian lebih pada kelompok yang sering terabaikan, demi terciptanya sistem klasifikasi yang lebih adil dan proporsional. Dengan demikian, pendekatan ini bukan sekadar teknik komputasi, tetapi juga dapat dilihat sebagai wujud dari keadilan proporsional dalam perspektif Islam.

6.3. Perbandingan kinerja model

Untuk mengukur kontribusi penggunaan *focal loss* secara lebih objektif, dilakukan perbandingan terhadap model *baseline* yang menggunakan fungsi *loss* konvensional, yaitu *cross entropy*. Perbandingan dilakukan berdasarkan sejumlah metrik evaluasi seperti *precision*, *recall*, *F1-score*, dan *confusion matrix*. Penerapan dua skema pembagian data dalam proses pengujian menunjukkan adanya

peningkatan kinerja pada kedua model, baik yang menggunakan *focal loss* maupun *cross entropy*. Skema pembagian 80:10:10 menghasilkan performa terbaik untuk masing-masing model. Meskipun keduanya mengalami peningkatan, model yang dilatih dengan *Focal Loss* tetap menunjukkan keunggulan performa dibandingkan dengan model *Cross Entropy*. Hasil perbandingan model *focal loss* dan *cross entropy* dengan *classification report* dapat dilihat pada tabel 6.1.

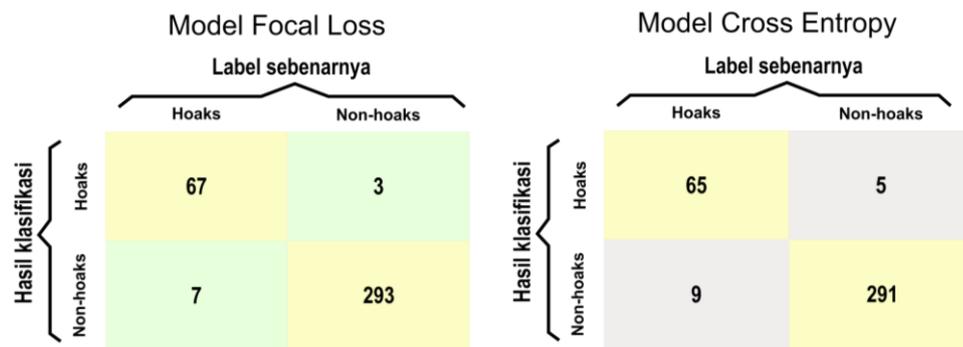
Tabel 6.10 Hasil perbandingan model *focal loss* dan *cross entropy*

Model	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>
<i>Focal Loss</i>	0.957	0.905	0.930	0.973
<i>Cross Entropy</i>	0.928	0.878	0.902	0.962

Tabel 6.1 menunjukkan bahwa *focal loss* mendapatkan nilai *f1-score* lebih tinggi dari *cross entropy*, ini menunjukkan bahwa *focal loss* dapat meningkatkan sensitivitas model terhadap kelas hoaks, yang merupakan tujuan utama dari pendekatan ini. Dari sisi lain akurasi keseluruhan, terjadi peningkatan dari 96,2% (*cross entropy*) menjadi 97,3% (*focal loss*). Perbedaan ini tidak hanya bersifat numerik, tetapi juga menunjukkan adanya peningkatan signifikan dalam keseimbangan kinerja antar kelas.

Evaluasi *confusion matrix* memberikan gambaran lebih rinci mengenai peningkatan tersebut. Model dengan *Cross Entropy* salah mengklasifikasikan 9 dari 74 data hoaks, sedangkan dengan *Focal Loss* jumlah kesalahan turun menjadi 7. Untuk kelas non-hoaks, dari 296 data, *cross entropy* salah mngklasifikasikan sebanyak 5 data, sedangkan *focal loss* kesalahan prediksi menurun menjadi hanya 3. *Focal loss* memberikan peningkatan performa yang konsisten. Oleh karena itu, pendekatan ini sangat direkomendasikan untuk digunakan dalam tugas klasifikasi

hoaks dengan distribusi kelas yang tidak seimbang, terutama jika fokus utama adalah pada peningkatan deteksi terhadap kelas minoritas (hoaks). Gambar 6.1 menunjukkan visualisasi *confusion matrix* pada model *focal loss* dan *cross entropy*



Gambar 6.17 Visualisasi *confusion matrix* pada perbandingan model

Secara umum, *focal loss* mampu meningkatkan performa klasifikasi terutama pada kelas hoaks, dengan peningkatan *f1-score* dan *recall* yang konsisten pada kedua skenario. Hal ini sesuai dengan tujuan utama *focal loss*, yaitu memberikan penalti lebih besar pada kesalahan klasifikasi data minoritas, sehingga model lebih fokus belajar pada data yang sulit diklasifikasi. Meskipun akurasi keseluruhan antara kedua *loss function* tidak terlalu signifikan, namun dalam konteks klasifikasi hoaks, *recall* dan *f1-score* pada kelas hoaks lebih penting daripada akurasi total. Dengan demikian, *focal loss* terbukti menjadi pendekatan yang lebih efektif untuk permasalahan klasifikasi tidak seimbang.

Penelitian ini diharapkan dapat memberikan kontribusi dalam membantu masyarakat bersikap lebih bijak dalam berinteraksi di ruang sosial, khususnya dalam menyikapi arus informasi yang masif. Penyebaran berita hoaks, baik secara sengaja maupun karena kelalaian dalam memverifikasi kebenarannya, merupakan tindakan yang bertentangan dengan nilai kejujuran. Perilaku tersebut tidak hanya

membahayakan dengan memicu keresahan dan fitnah, tetapi juga dapat menimbulkan perpecahan di tengah masyarakat. Dalam perspektif Islam, tindakan semacam ini dikategorikan sebagai bentuk kejahatan sosial yang dikecam keras. Islam menganjurkan prinsip *tabayyun*, yaitu sikap kehati-hatian dan klarifikasi terhadap setiap informasi yang diterima, sebagaimana telah diajarkan oleh Rasulullah *Shallallahu ‘Alaihi Wasallam*.

كَفَى بِالْمَرْءِ كَذِبًا أَنْ يُحَدِّثَ بِكُلِّ مَا سَمِعَ (رواه مسلم)

Artinya: Cukuplah seseorang dianggap berdosa jika ia menceritakan segala yang ia dengar” (HR Muslim).

Hadis ini menekankan larangan menyebarkan informasi tanpa memverifikasi kebenarannya terlebih dahulu. Dalam konteks digital saat ini, pesan moral dari hadis ini menjadi sangat relevan, mengingat deras nya arus informasi yang belum tentu akurat namun mudah tersebar luas melalui media sosial dan platform daring lainnya. Hadis ini mendorong umat untuk bersikap selektif, berhati-hati, dan memiliki rasa tanggung jawab dalam menerima maupun menyebarkan berita. Melalui penelitian ini, yang mengembangkan model klasifikasi berita hoaks berbasis IndoBERT dengan metode *fine-tuning*, diharapkan dapat menjadi kontribusi konkret dalam mendukung literasi digital masyarakat. Selain itu, hasil penelitian ini diharapkan dapat meningkatkan kesadaran kolektif akan pentingnya bersikap kritis, rasional, dan etis dalam menyikapi setiap informasi yang diterima, sehingga tidak mudah terjebak dalam arus penyebaran hoaks yang merugikan.

BAB VII

KESIMPULAN

7.1. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi berita hoaks berbahasa Indonesia dengan menggunakan pendekatan *fine-tuning* IndoBERT dan penerapan fungsi *Focal Loss* untuk mengatasi data tidak seimbang. Berdasarkan hasil eksperimen dan analisis yang telah dilakukan, dapat disimpulkan beberapa hal sebagai berikut:

- a. IndoBERT memiliki kemampuan representasi bahasa Indonesia yang kuat. Hasil *fine-tuning* menunjukkan bahwa model ini mampu mengklasifikasikan teks secara akurat dalam konteks bahasa Indonesia, termasuk dalam membedakan antara konten hoaks dan non-hoaks, walaupun dengan struktur Bahasa yang kompleks.
- b. *Focal Loss* efektif dalam menangani ketidakseimbangan kelas, terutama dalam meningkatkan performa deteksi terhadap kelas minoritas (hoaks). Model yang menggunakan *Focal Loss* mencatat peningkatan metrik evaluasi seperti *F1-score* menjadi 0,9306 untuk kelas hoaks, *precision* 0,9571, dan *recall* 0,9054, serta peningkatan akurasi keseluruhan menjadi 97,29%.
- c. Dua skema pelatihan yang dilakukan menunjukkan bahwa skema pembagian data 80:10:10 lebih unggul dalam menangani ketidakseimbangan data. Selain itu Pendekatan *focal loss* lebih unggul dibandingkan *cross entropy*. Evaluasi

terhadap model baseline yang menggunakan *cross entropy* menunjukkan bahwa meskipun model tersebut cukup baik, performa terhadap kelas hoaks masih lebih rendah. *focal loss* terbukti meningkatkan sensitivitas dan presisi terhadap kelas hoaks tanpa mengorbankan kinerja pada kelas non-hoaks.

Dari keseluruhan hasil tersebut, dapat disimpulkan bahwa penggunaan skema pembagian data 80:10:10 pada menggunakan model *Focal Loss* dalam *fine-tuning* IndoBERT merupakan strategi yang efektif dan relevan untuk tugas klasifikasi dengan data tidak seimbang, khususnya dalam konteks deteksi berita hoaks berbahasa Indonesia.

7.2. Saran

Berdasarkan hasil dan keterbatasan dalam penelitian ini, beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

- a. Penggunaan dataset yang lebih besar dan bervariasi. Untuk meningkatkan generalisasi model, dan dilakukan pelatihan pada dataset yang mencakup lebih banyak topik, sumber berita, dan variasi gaya penulisan.
- b. Eksplorasi teknik *augmentasi* data. Untuk menangani ketidakseimbangan data secara lebih proaktif, penelitian selanjutnya dapat mempertimbangkan teknik data *augmentation* berbasis NLP.
- c. Evaluasi terhadap jenis hoaks yang lebih spesifik. Akan lebih menarik jika model tidak hanya mengklasifikasikan antara hoaks dan non-hoaks, tetapi juga mendeteksi jenis hoaks seperti politik, kesehatan, ekonomi, sehingga dapat digunakan sebagai sistem pendukung kebijakan yang lebih komprehensif.

REFERENSI

- Abidin, T., & Wiyono, S. (2017). Rancang Bangun Sistem Informasi Kemahasiswaan (Studi Kasus: Program Studi D IV Teknik Informatika Politeknik Harapan Bersama Tegal). *Jurnal Informatika: Jurnal Pengembangan IT*, 2(1), 30–36. <https://doi.org/10.30591/jpit.v2i1.439>
- Aggarwal, A., Chauhan, A., Kumar, D., Mittal, M., & Verma, S. (2020). Classification of Fake News by Fine-tuning Deep Bidirectional Transformers based Language Model. *EAI Endorsed Transactions on Scalable Information Systems*, 7(27), 1–12. <https://doi.org/10.4108/eai.13-7-2018.163973>
- Almeida, T. A., Hidalgo, J. M. G., & Yamakami, A. (2011). *Contributions to the study of SMS spam filtering*. 259–262. <https://doi.org/10.1145/2034691.2034742>
- Altnel, B., & Ganiz, M. C. (2018). Semantic text classification: A survey of past and recent advances. *Information Processing and Management*, 54(6), 1129–1153. <https://doi.org/10.1016/j.ipm.2018.08.001>
- Bardab, S. N., Ahmed, T. M., & Mohammed, T. A. A. (2021). Data mining classification algorithms: An overview. *International Journal of Advanced and Applied Sciences*, 8(2), 1–5. <https://doi.org/10.21833/ijaas.2021.02.001>
- Buda, M., Maki, A., & Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249–259. <https://doi.org/10.1016/j.neunet.2018.07.011>
- Cai, Z., Li, Z., Liu, Y., Guo, L., & Song, Y. (2025). *Ustnlp16 at SemEval-2025 Task 9: Improving Model Performance through Imbalance Handling and Focal Loss*.
- Devlin, J., Chang, M.-W., Lee, K., Google, K. T., & Language, A. I. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Naacl-Hlt 2019, Mlm*, 4171–4186. <https://aclanthology.org/N19-1423.pdf>
- Fathin, M. A., Sibaroni, Y., & Prasetyowati, S. S. (2024). Handling Imbalance Dataset on Hoax Indonesian Political News Classification using IndoBERT and Random Sampling. *Jurnal Media Informatika Budidarma*, 8(1), 352. <https://doi.org/10.30865/mib.v8i1.7099>
- Geni, L., Yulianti, E., & Sensuse, D. I. (2023). Sentiment Analysis of Tweets Before the 2024 Elections in Indonesia Using IndoBERT Language Models. *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)*, 9(3), 746–757. <https://doi.org/10.26555/jiteki.v9i3.26490>
- Gumilar, G., Justito, A., & Nunik, M. (2017). Literasi Media: Cerdas Menggunakan Media Sosial Dalam Menanggulangi Berita Palsu (Hoax) Oleh Siswa Sma. *Pengabdian Kepada Masyarakat*, 1(1), 35–40. <https://doi.org/1410-5675>

- Hariharan, R. L., & Anand Kumar, M. (2023). NITK-IT-NLP@DravidianLangTech-2023: Impact of Focal Loss on Malayalam Fake News Detection using Transformers. *DravidianLangTech 2023 - 3rd Workshop on Speech and Language Technologies for Dravidian Languages, associated with 14th International Conference on Recent Advances in Natural Language Processing, RANLP 2023 - Proceedings*, 207–210. https://doi.org/10.26615/978-954-452-085-4_029
- Hu, Q., Guo, Y., Cordy, M., Xie, X., Ma, L., Papadakis, M., & Le Traon, Y. (2022). An Empirical Study on Data Distribution-Aware Test Selection for Deep Learning Enhancement. *ACM Transactions on Software Engineering and Methodology*, 31(4). <https://doi.org/10.1145/3511598>
- Ibnu Katsir. (2003). Tafsir Ibnu Katsir (E. M. Ghofar, A. Mu'thi, & A. I. Al-Atsari, Terjemah; Jilid 1). Bogor: Pustaka Imam Asy-Syafi'i.
- Ibnu Katsir. (2003). Tafsir Ibnu Katsir (E. M. Ghofar, A. Mu'thi, & A. I. Al-Atsari, Terjemah; Jilid 2). Bogor: Pustaka Imam Asy-Syafi'i.
- Ibnu Katsir. (2004). Tafsir Ibnu Katsir (E. M. Ghofar, A. Mu'thi, & A. I. Al-Atsari, Terjemah; Jilid 7). Bogor: Pustaka Imam Asy-Syafi'i.
- Isa, S. M., Nico, G., & Permana, M. (2022). Indobert for Indonesian Fake News Detection. *ICIC Express Letters*, 16(3), 289–297. <https://doi.org/10.24507/icicel.16.03.289>
- Jiang, D. (2021). *Text Semantic Classification of Long Discourses Based on Neural Networks with Improved Focal Loss*. 2021.
- Juarto, B., & Yulianto. (2023). Indonesian News Classification Using IndoBERT. *International Journal of Intelligent Systems and Applications in Engineering*, 11(2), 454–460.
- Kaliyar, R. K., Goswami, A., & Narang, P. (2021). FakeBERT: Fake news detection in social media with a BERT-based deep learning approach. *Multimedia Tools and Applications*, 80(8), 11765–11788. <https://doi.org/10.1007/s11042-020-10183-2>
- Kementerian Agama Republik Indonesia. (2019). Tafsir Al-Qur'an Kementerian Agama Republik Indonesia [Versi digital]. <https://quran.kemenag.go.id/quran/per-ayat/surah/25?from=32&to=32>
- Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–15.
- Li, C., Zhang, C., & Fu, Q. (2020). Research on CNN + LSTM user intention classification based on multi-granularity features of texts. *The Journal of Engineering*, 2020(13), 486–490. <https://doi.org/10.1049/joe.2019.1175>

- Lin, C. J., Wang, J. G., & Lee, C. Y. (2009). Pattern recognition using neural-fuzzy networks based on improved particle swarm optimization. *Expert Systems with Applications*, 36(3 PART 1), 5402–5410. <https://doi.org/10.1016/j.eswa.2008.06.110>
- Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollar, P. (2017). Focal Loss for Dense Object Detection. *Proceedings of the IEEE International Conference on Computer Vision, 2017-October*, 2999–3007. <https://doi.org/10.1109/ICCV.2017.324>
- Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, 5(4), 1093–1113. <https://doi.org/10.1016/j.asej.2014.04.011>
- Modanwal, G., & Sarawadekar, K. (2016). Development of a new dactylology and writing support system especially for blinds. *Proceedings - 2016 13th Conference on Computer and Robot Vision, CRV 2016*, 362–369. <https://doi.org/10.1109/CRV.2016.65>
- Noorian, A., Harounabadi, A., & Hazratifard, M. (2024). A sequential neural recommendation system exploiting BERT and LSTM on social media posts. *Complex and Intelligent Systems*, 10(1), 721–744. <https://doi.org/10.1007/s40747-023-01191-4>
- Oad, A., Farooq, H., Zafar, A., Akram, B. A., Zhou, R., & Dong, F. (2024). Fake News Classification Methodology with Enhanced BERT. *IEEE Access*, 12(October), 164491–164502. <https://doi.org/10.1109/ACCESS.2024.3491376>
- Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- Pramiyati, T. (2017). *Peran Data Primer Pada Pembentukan Skema Konseptual Yang Faktual (Studi Kasus : Skema Konseptual Basisdata Simbumil)*. 8(2), 679–686.
- Pudjihartono, N., Fadason, T., Kempa-Liehr, A. W., & O’Sullivan, J. M. (2022). A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction. *Frontiers in Bioinformatics*, 2(June), 1–17. <https://doi.org/10.3389/fbinf.2022.927312>
- Rahmawati, A., Alamsyah, A., & Romadhony, A. (2022). Hoax News Detection Analysis using IndoBERT Deep Learning Methodology. *2022 10th International Conference on Information and Communication Technology, ICoICT 2022, August 2022*, 368–373. <https://doi.org/10.1109/ICoICT55009.2022.9914902>
- Raza, S., Paulen-Patterson, D., & Ding, C. (2025). Fake news detection: comparative evaluation of BERT-like models and large language models with

- generative AI-annotated data. *Knowledge and Information Systems*, 1–30. <https://doi.org/10.1007/s10115-024-02321-1>
- Ridho, M. Y., & Yulianti, E. (2024). *From Text to Truth : Leveraging IndoBERT and Machine Learning Models for Hoax Detection in Indonesian News*. *10*(3), 544–555. <https://doi.org/10.26555/jiteki.v10i3.29450>
- Rogers, A., Kovaleva, O., & Rumshisky, A. (2020). A primer in bertology: What we know about how bert works. *Transactions of the Association for Computational Linguistics*, *8*, 842–866. https://doi.org/10.1162/tacl_a_00349
- Shishah, W. (2022). JointBert for Detecting Arabic Fake News. *IEEE Access*, *10*(July), 71951–71960. <https://doi.org/10.1109/ACCESS.2022.3185083>
- Sinapoy, M. I. K., Sibaroni, Y., & Prasetyowati, S. S. (2023). *JURNAL RESTI Comparison of LSTM and IndoBERT Method*. *5*(158), 2–6.
- Suadaa, L. H., Santoso, I., Tabitha, A., & Panjaitan, B. (2021). *Transfer Learning of Pre-trained Transformers for Covid-19 Hoax Detection in Indonesian Language*. *15*(3), 317–326.
- Tobing, C. J. L., Wijayakusuma, I. G. N. L., Putu, L., Harini, I., & Udayana, U. (2025). *Detection of Political Hoax News Using Fine-Tuning IndoBERT*. *9*(2), 354–360.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems, 2017-Decem(Nips)*, 5999–6009.
- Verma, P. K., Agrawal, P., Madaan, V., & Prodan, R. (2023). MCred: multi-modal message credibility for fake news detection using BERT and CNN. *Journal of Ambient Intelligence and Humanized Computing*, *14*(8), 10617–10629. <https://doi.org/10.1007/s12652-022-04338-2>
- Vosoughi, S., Roy, D., & Aral, S. (2018). News On-line. *Science*, *1151*(March), 1146–1151.
- Wu, S. (2013). A review on coarse warranty data and analysis. *Reliability Engineering and System Safety*, *114*(1), 1–11. <https://doi.org/10.1016/j.ress.2012.12.021>
- Yang, R., Singh, S. K., Tavakkoli, M., Amiri, N., Yang, Y., Karami, M. A., & Rai, R. (2020). CNN-LSTM deep learning architecture for computer vision-based modal frequency detection. *Mechanical Systems and Signal Processing*, *144*, 106885. <https://doi.org/10.1016/j.ymsp.2020.106885>
- Yefferson, D. Y., Lawijaya, V., & Girsang, A. S. (2024). Hybrid model: IndoBERT and long short-term memory for detecting Indonesian hoax news. *IAES International Journal of Artificial Intelligence*, *13*(2), 1911–1922. <https://doi.org/10.11591/ijai.v13.i2.pp1913-1924>
- Zhang, T., Wang, D., Chen, H., Zeng, Z., Guo, W., Miao, C., & Cui, L. (2020).

BDANN: BERT-Based Domain Adaptation Neural Network for Multi-Modal Fake News Detection. *Proceedings of the International Joint Conference on Neural Networks*, August.
<https://doi.org/10.1109/IJCNN48605.2020.9206973>

Zou, H., & Wang, Z. (2023). A semi - supervised short text sentiment classification method based on improved Bert model from unlabelled data. *Journal of Big Data*. <https://doi.org/10.1186/s40537-023-00710-x>