

**MODEL PERINGKASAN ABSTRAKTIF PADA ARTIKEL BERBAHASA  
INDONESIA MENGGUNAKAN BI-GRU DAN LSTM**

**TESIS**

**Oleh:  
ANDRI SETIAWAN  
NIM. 230605210019**



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

**MODEL PERINGKASAN ABSTRAKTIF PADA ARTIKEL BERBAHASA  
INDONESIA MENGGUNAKAN BI-GRU DAN LSTM**

**TESIS**

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:  
**ANDRI SETIAWAN**  
**NIM. 230605210019**

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

**HALAMAN PERSETUJUAN**  
**MODEL PERINGKASAN ABSTRAKTIF PADA ARTIKEL BERBAHASA**  
**INDONESIA MENGGUNAKAN BI-GRU DAN LSTM**

**TESIS**

**Oleh:**  
**ANDRI SETIAWAN**  
**NIM. 230605210019**

Telah Diperiksa dan Disetujui untuk Diuji  
Tanggal: 2025

Pembimbing I,



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

Pembimbing II,



Dr. M. Imamudin Lc, MA  
NIP. 19740602 200901 1 010

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



Prof. Dr. Ir. Muhammad Faisal, M.T  
NIP. 19740510 200501 1 007

**HALAMAN PENGESAHAN**  
**MODEL PERINGKASAN ABSTRAKTIF PADA ARTIKEL BERBAHASA**  
**INDONESIA MENGGUNAKAN BI-GRU DAN LSTM**

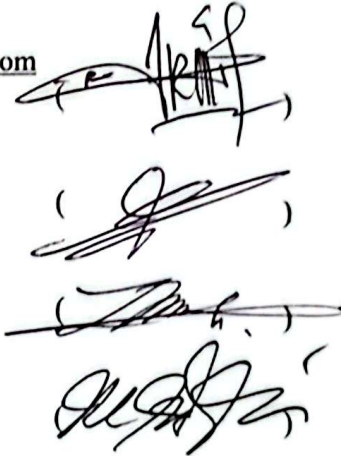
**TESIS**

**Oleh:**  
**ANDRI SETIAWAN**  
**NIM. 230605210019**

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

**Susunan Dewan Penguji**

Penguji I	: <u>Dr. Ririen Kusumawati, S.Si., M.Kom</u> NIP. 19720309 200501 2 002
Penguji II	: <u>Dr. Cahyo Crysdiyan, MCS</u> NIP. 19740424 200901 1 008
Pembimbing I	: <u>Dr. Zainal Abidin, M.Kom</u> NIP. 19760613 200501 1 004
Pembimbing II	: <u>Dr. M. Imamudin Lc, MA</u> NIP. 19740602 200901 1 010



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



Prof. Dr. Ir. Muhammad Faisal, M.T  
NIP. 19740510 200501 1 007

## PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini:

Nama : Andri Setiawan  
NIM : 230605210019  
Program Studi : Magister Informatika  
Fakultas : Sains dan Teknologi

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

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

Malang, 22 Desember 2025  
Yang membuat pernyataan,

ANDRI SETIAWAN  
NIM. 230605210019

## **MOTTO**

*“Takdir manusia memang sudah ditentukan sejak lahir, tapi dengan kerja keras,  
kita dapat mengalahkan takdir”.*

*~Naruto Uzumaki~*

## HALAMAN PERSEMBAHAN

*Bismillāhirrahmānirrahīm.* Dengan izin dan pertolongan Allah SWT, saya persembahkan Tesis ini kepada:

1. Keluarga kami dan orang tua kami, istri tercinta Ifa Amalia Anwar, Bapak Jumangin, Ibu Murtini, yang telah memberikan dukungan, doa, dan keikhlasan dalam setiap langkah yang saya tempuh. Ucapan terima kasih khusus juga saya sampaikan kepada putri kami, Avareen Najwa Mumtaza, yang selalu menjadi sumber semangat dan kebahagiaan.
2. Para dosen kami, Bapak Dr. Zainal Abidin, M.Kom., dan Bapak Dr. M. Imamudin, Lc., M.A., yang telah memberikan bimbingan, ilmu, dan wawasan yang sangat berharga. Terima kasih atas dedikasi dan perhatian yang telah memperkaya pemahaman serta perjalanan akademik kami.
3. Teman-teman seperjuangan Angkatan 8 S2 Informatika yang saling mendukung, dan saling membantu dalam proses menuntut ilmu.
4. Teman-teman Pondok Beras 99, yang dengan tulus menerima kehadiran kami dan menyediakan tempat tinggal selama menempuh studi di Malang. Terima kasih atas kebersamaan, dukungan, serta kenyamanan yang telah diberikan sepanjang perjalanan ini.

*jazakumullah ahsanal jaza,* Semoga Allah senantiasa membimbing kita ke jalan yang lurus, memudahkan setiap langkah dalam mewujudkan mimpi-mimpi kita, serta membalas seluruh kebaikan dengan balasan terbaik. *Aamiin ya Rabbal ‘Alamiin.*

## KATA PENGANTAR

*Assalamu'alaikum warahmatullahi wabarakatuh*

Puji syukur penulis panjatkan kehadiran Allah SWT, atas rahmat dan karuniaNya sehingga penulis dapat menyelesaikan thesis ini yang berjudul “*Model Peringkasan Abstraktif Pada Artikel Berbahasa Indonesia Menggunakan Bi-GRU dan LSTM*”.

Dalam penulisan skripsi ini, penulis menyadari banyak pihak yang terlibat baik dalam proses membimbing penulisan dan juga memberikan semangat dan dukungan moral atau material. Untuk itu, penulis ingin menyampaikan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Prof. Dr. Muhammad Faisal, M.T., selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Dr. Zainal Abidin, M.Kom., selaku Dosen Pembimbing I yang telah memberikan banyak dukungan dan bimbingan dalam penulisan tesis ini.
5. Dr. M. Imamudin Lc, MA., selaku Dosen Pembimbing II yang telah memberikan arahan dalam penulisan tesis ini.
6. Dr. Ririen Kusumawati, S.Si., M.Kom., selaku Ketua Penguji yang telah memberikan masukan dan saran untuk menyelesaikan tesis ini.



7. Dr. Cahyo Crysdiyan, MCS., selaku Anggota Dosen Penguji yang telah memberikan saran untuk menyelesaikan tesis ini.
8. Seluruh Dosen dan Jajaran Staf Program Studi Magister Informatika yang telah memberikan banyak bantuan dalam tesis ini.
9. Kedua orang tua, Bapak Jumangin dan Ibu Murtini serta Istriku Ifa Amalia Anwar dan Ananda Avareen Najwa Mumtaza yang telah memberikan dukungan kepada penulis untuk menyelesaikan tesis ini.
10. Teman-teman Angkatan 2023 Magister Informatika yang telah memberikan banyak bantuan baik material maupun dukungan intelektual, semangat, serta motivasi dalam menyelesaikan penyusunan tesis ini.
11. Semua pihak yang tidak dapat disebutkan satu per satu, termasuk responden yang telah memberikan kontribusi, saran, dan dukungan dalam perjalanan penulisan tesis ini.
12. Teman-teman Pondok Beras 99 Bengawan Solo.

Akhir kata, penulis mengakui bahwa penulisan pada tesis ini masih banyak kekurangan.

Wassalamualaikum Warahmatullahi Wabarakatuh.

Malang, Desember 2025

Penulis

## DAFTAR ISI

<b>COVER .....</b>	<b>i</b>
<b>HALAMAN PERSETUJUAN.....</b>	<b>ii</b>
<b>HALAMAN PENGESAHAN .....</b>	<b>iii</b>
<b>PERNYATAAN KEASLIAN .....</b>	<b>iv</b>
<b>MOTTO .....</b>	<b>v</b>
<b>HALAMAN PERSEMBAHAN.....</b>	<b>vi</b>
<b>KATA PENGANTAR.....</b>	<b>vii</b>
<b>DAFTAR ISI.....</b>	<b>ix</b>
<b>DAFTAR TABEL.....</b>	<b>xii</b>
<b>DAFTAR GAMBAR.....</b>	<b>xiii</b>
<b>ABSTRAK .....</b>	<b>xiv</b>
<b>ABSTRACT .....</b>	<b>xv</b>
<b>المخلص.....</b>	<b>xvi</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Pernyataan Masalah .....	5
1.3 Tujuan Penelitian .....	6
1.4 Batasan Penelitian .....	6
1.5 Manfaat Penelitian .....	7
<b>BAB II STUDI PUSTAKA .....</b>	<b>8</b>
2.1 Peringkasan Abstraktif dalam Bahasa Indonesia .....	8
2.2 Pentingnya Peringkasan Text.....	9
2.3 RNN .....	11
2.4 LSTM .....	11
2.5 BIGRU .....	12
2.6 Tabel Penelitian Terdahulu .....	13
2.7 Kerangka Teori.....	20
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>21</b>
3.1 Kerangka Konsep .....	21

3.2 Design Penelitian .....	23
3.3 Design Sistem.....	24
3.4 Dataset.....	25
3.5 Preprocessing .....	26
3.5.1 Case Folding.....	27
3.5.2 Sentence Tokenization .....	27
3.5.3 Word Tokenization.....	28
3.6 Peringkasan Ekstraktif .....	28
3.6.1 Ekstraksi Fitur .....	29
3.6.2 Penilaian.....	32
a. Penilaian Statistik (Cosine TF-IDF).....	33
b. Penilaian Semantik(Cosine SBERT).....	34
c. Penggabungan dan Seleksi.....	34
3.7 Peringkasan Abstraktif.....	35
3.7.1 Arsitektur Encoder-Decoder .....	35
3.7.2 Encoder BiGRU .....	36
3.7.3 Mekanisme Penghubung (BRIDGE).....	36
3.7.4 Decoder LSTM.....	37
3.8 Skenario Pengujian dan Evaluasi .....	37
3.8.1 Lingkungan Pengujian .....	38
3.8.2 Hyperparameter Training.....	39
3.8.3 Metode Evaluasi.....	40
<b>BAB IV MODEL RINGKASAN EKSTRAKTIF .....</b>	<b>42</b>
4.1 Implementasi dan Pemilihan Model (Model Implementation) .....	42
4.1.1 Distribusi Jumlah Kalimat Perartikel .....	42
4.1.2 Distribusi Jumlah Kalimat pada Ringkasan Asli .....	43
4.1.3 Realisasi Pra-Pemrosesan Data (Data Preparation) .....	44
a. Case Folding.....	44
b. Sentence Tokenization .....	45
c. Word Tokenization.....	46
4.2 Realisasi Ekstraksi Fitur TF-IDF .....	47
4.3 Implementasi SBERT (Semantic Embedding).....	48
4.4 Cosine Similarity.....	48
4.4.1 CS TF-IDF .....	49
4.4.2 CS SBERT .....	49
4.5 Penilaian.....	49
4.6 Hasil Peringkasan Ekstraktif.....	50
4.7 Analisis Hasil .....	52
<b>BAB V PERINGKASAN ABSTRAKTIF DENGAN SOURCE</b>	
<b>PERINGKASAN EKSTRAKTIF .....</b>	<b>55</b>

5.1 Desain Sistem.....	55
5.2 Word2Vec Embedding.....	55
5.2.1 Hasil Preprocessing.....	56
5.2.2 Representasi Numeric .....	56
5.2.3 Vektorisasi.....	57
5.3 Proses Training.....	58
5.4 Hasil Ringkasan .....	59
<b>BAB VI PERINGKASAN ABSTRAKTIF DENGAN SOURCE ARTIKEL</b>	<b>60</b>
6.1 Desain Sistem.....	60
6.2 Word2vec Embedding.....	60
6.3 Proses Training.....	61
6.4 Hasil Peringkasan.....	62
<b>BAB VII PEMBAHASAN .....</b>	<b>64</b>
7.1 Hasil Pelatihan (Training Loss) .....	64
7.2 Perbandingan Kinerja ROUGE .....	66
<b>BAB VIII KESIMPULAN DAN SARAN .....</b>	<b>70</b>
8.1 Kesimpulan .....	70
8.2 Saran.....	71
<b>DAFTAR PUSTAKA .....</b>	<b>72</b>

## DAFTAR TABEL

Tabel 2. 1 Tabel Review .....	14
Tabel 3. 1 Tabel Dataset.....	26
Tabel 3. 2 Contoh hasil Case Folding .....	27
Tabel 3. 3 Contoh Hasil Tokenisasi Kalimat .....	27
Tabel 3. 4 Contoh Hasil Tokenisasi Kata.....	28
Tabel 3. 5 Contoh Peringkasan Ekstraktif.....	29
Tabel 4. 1 Hasil <i>case folding</i> .....	44
Tabel 4. 2 Hasil Sentence Tokenization.....	45
Tabel 4. 3 Hasil dari word tokenization .....	46
Tabel 4. 4 Penilaian menggunakan TF-IDF .....	47
Tabel 4. 5 Hasil SBERT .....	48
Tabel 4. 6 Hasil CS TF-IDF .....	49
Tabel 4. 7 Hasil CS SBERT .....	49
Tabel 4. 8 Hasil penggabungan .....	50
Tabel 4. 9 Contoh Hasil .....	50
Tabel 4. 10 Statistik Hasil ROUGE score .....	52
Tabel 5. 1 Hasil Vektorisasi .....	56
Tabel 5. 2 Hasil Vektorisasi .....	57
Tabel 5. 3 Hasil Peringkasan Abstraktif.....	59
Tabel 6. 1 Contoh hasil peringkasan abstraktif.....	62

## DAFTAR GAMBAR

Gambar 2.1 Kerangka Teori.....	20
Gambar 3.1 Kerangka Konsep .....	21
Gambar 3.2 Design Penelitian.....	23
Gambar 3.3 Design Sistem.....	24
Gambar 4.1 Distribusi jumlah kalimat setiap artikel .....	42
Gambar 4.2 Distribusi Jumlah Kalimat pada Ringkasi Asli .....	43
Gambar 5.1 Desain sistem dengan source peringkasan ekstraktif.....	55
Gambar 5.2 Training dengan input peringkasan ekstraktif.....	58
Gambar 6.1 Desain sistem dengan source artikel .....	60
Gambar 6.2 Proses training dengan input teks artikel keseluruhan .....	61
Gambar 7.1 Training dengan input peringkasan ekstraktif.....	64
Gambar 7.2 Training dengan input teks artikel.....	65
Gambar 7.3 Perbandingan Kinerja ROUGE .....	66

## ABSTRAK

Setiawan, Andri. 2025. **MODEL PERINGKASAN ABSTRAKTIF PADA ARTIKEL BERBAHASA INDONESIA MENGGUNAKAN BI-GRU DAN LSTM.**  
Tesis. Program Studi Teknik Informatika Fakultas Sains dan Teknologi  
Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I)  
Dr. Zainal Abidin, M.Kom. (II) Dr. M. Imamudin Lc, MA

**Kata kunci:** *NLP, Extractive Summarization, Abstractive Summarization, Bi-GRU, LSTM*

Perkembangan pesat konten berita daring pada era digital menuntut solusi efisien untuk mengekstraksi informasi penting dari volume teks yang semakin besar. Peringkasan abstraktif menawarkan jawaban ideal dengan menghasilkan ringkasan yang padat, koheren, dan menyerupai tulisan manusia, namun dalam implementasinya pada bahasa Indonesia masih terbatas karena kompleksitas linguistik dan keterbatasan dataset berkualitas tinggi. Untuk mengatasi tantangan ini, penelitian ini mengusulkan kerangka kerja peringkasan hibrida yang menggabungkan tahap ekstraktif. Pertama, kalimat-kalimat inti dipilih menggunakan pembobotan TF-IDF dan penilaian semantik berbasis SBERT untuk menghasilkan input yang terfokus. Kemudian, model abstraktif berbasis RNN terdiri dari encoder Bi-GRU, dan decoder LSTM digunakan untuk menghasilkan ringkasan akhir. Evaluasi menunjukkan bahwa model abstraktif mencapai performa moderat namun menjanjikan. Lebih penting lagi, perbandingan eksperimen menunjukkan bahwa model mencapai performa jauh lebih tinggi ketika menggunakan input ringkasan ekstraktif (ROUGE-1: 0.5439, ROUGE-L: 0.5205) dibandingkan teks artikel lengkap (ROUGE-1: 0.4123, ROUGE-L: 0.3793), mengindikasikan bahwa preprocessing ekstraktif sangat krusial untuk meningkatkan kohesi dan akurasi ringkasan. Hasil ini membuktikan bahwa arsitektur RNN tetap relevan dan efektif untuk peringkasan abstraktif bahasa Indonesia jika didukung oleh input yang terfilter, tanpa harus bergantung pada model transformer berukuran besar. Secara keseluruhan, penelitian ini memberikan kontribusi praktis berupa sistem ringkas yang ringan, efisien, dan peka konteks, cocok untuk aplikasi nyata di lingkungan sumber daya terbatas.

## ABSTRACT

Setiawan, Andri. 2025, **ABSTRACTIVE SUMMARIZATION MODEL FOR INDONESIAN ARTICLES USING BI-GRU AND LSTM**. Thesis. Department of Informatics Engineering Faculty of Science and Technology Maulana Malik Ibrahim State Islamic University Malang. Supervisor: (I) Dr. Zainal Abidin, M.Kom. (II) Dr. M. Imamudin Lc, MA

**Keywords :** *NLP, Extractive Summarization, Abstractive Summarization, Bi-GRU, LSTM*

The rapid development of online news content in the digital age demands efficient solutions for extracting important information from increasingly large volumes of text. Abstractive summarization offers an ideal answer by producing concise, coherent summaries that resemble human writing, but its implementation in Indonesian is still limited due to linguistic complexity and the scarcity of high-quality datasets. To address these challenges, this study proposes a hybrid summarization framework that combines extractive and abstractive stages. First, key sentences are selected using TF-IDF weighting and SBERT-based semantic scoring to generate focused input. Then, an RNN-based abstractive model consisting of a Bi-GRU encoder and an LSTM decoder is used to generate the final summary. The evaluation shows that the abstractive model achieves moderate but promising performance. More importantly, experimental comparisons show that the model achieves significantly higher performance when using extractive summary input (ROUGE-1: 0.5439, ROUGE-L: 0.5205) compared to full article text (ROUGE-1: 0.4123, ROUGE-L: 0.3793), indicating that extractive preprocessing is crucial for improving the cohesion and accuracy of summaries. These results prove that RNN architecture remains relevant and effective for abstractive summarization of Indonesian language when supported by filtered input, without having to rely on large transformer models. Overall, this research provides a practical contribution in the form of a lightweight, efficient, and context-sensitive summarization system, suitable for real-world applications in resource-constrained environments.



## الملخص

سينياوان، أندري. 2025. نموذج التلخيص التجريدي التلقائي للمقالات باللغة الإندونيسية. رسالة جامعية. قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الاول: د. زين العابدين، الما جستير، د. محمد إمام الدين، الما جستير.

الكلمات الرئيسية: NLP، التلخيص الاستخلاصي، التلخيص التجريدي، LSTM، Bi-GRU

تطلب التطور السريع لمحتوى الأخبار عبر الإنترنت في العصر الرقمي حلولاً فعالة لاستخراج المعلومات المهمة من أحجام متزايدة من النصوص. يقدم التلخيص التجريدي حلاً مثالياً من خلال إنتاج ملخصات موجزة ومتسقة تشبه الكتابة البشرية. ومع ذلك، لا يزال تطبيقه في اللغة الإندونيسية محدوداً بسبب التعقيد اللغوي وندرة مجموعات البيانات عالية الجودة. لمواجهة هذه التحديات، تقترح هذه الدراسة إطاراً توليفياً للملخصات يجمع بين المراحل الاستخلاصية والتجريدية. أولاً، يتم اختيار الجمل الرئيسية باستخدام ترجيح TF-IDF والتقييم الدلالي القائم على SBERT لإنتاج مدخلات مركزة. ثم يتم استخدام نموذج تجريدي قائم على RNN يتكون من مشفر Bi-GRU ومفكك LSTM لإنشاء الملخص النهائي. يُظهر التقييم أن النموذج التجريدي يحقق أداءً متواضعاً ولكنه واعد. والأهم من ذلك، تُظهر المقارنات التجريبية أن النموذج يحقق أداءً أعلى بكثير عند استخدام مدخلات الملخص الاستخراجي (-ROUGE ROUGE-L: 0.5205، ROUGE-1: 0.5439) مقارنةً بنص المقالة الكامل (ROUGE-L: 0.4123، ROUGE-1: 0.3793)، مما يشير إلى أن المعالجة الأولية الاستخلاصية ضرورية لتحسين تماسك ودقة الملخصات. تثبت هذه النتائج أن بنية RNN لا تزال ملائمة وفعالة للتلخيص التجريدي للغة الإندونيسية عندما تكون مدعومة بمدخلات مفككة، دون الحاجة إلى الاعتماد على نماذج محولات كبيرة. بشكل عام، يقدم هذا البحث مساهمة عملية في شكل نظام موجز وخفيف الوزن وفعال وحساس للسياق، ومناسب للتطبيقات الواقعية في البيئات المحدودة الموارد.

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Di era digital saat ini, arus informasi terus meningkat seiring dengan kemajuan teknologi dan kemudahan akses terhadap berbagai sumber berita online (Juditha, 2013). Setiap hari, masyarakat dihadapkan dengan volume berita yang besar dari berbagai media, baik lokal maupun internasional (Nur, 2021). Kondisi ini menimbulkan tantangan bagi banyak orang dalam menyaring dan memahami informasi yang esensial di antara berbagai sumber yang mungkin memiliki topik serupa namun menyajikan sudut pandang atau detail yang berbeda (Rusi dkk., 2023). Di sinilah pentingnya sistem peringkasan yang mampu menyediakan ringkasan informasi yang relevan, ringkas, dan komprehensif bagi para pembaca (Mustaqhfiri dkk., 2012).

Peringkasan teks, khususnya dalam konteks berita, menjadi solusi yang efektif untuk membantu pembaca memahami inti informasi dengan lebih cepat dan efisien (Zamzam dkk., 2020). Model peringkasan berita tidak hanya dituntut untuk mengidentifikasi informasi yang penting, tetapi juga harus mampu mengurangi redundansi, menjaga koherensi, dan memastikan informasi yang disampaikan tetap akurat (Yuliska & Syaliman, 2020). Hal ini sangat relevan karena berita tentang topik yang sama sering kali tersebar di berbagai artikel dari berbagai sumber, dengan sudut pandang yang beragam (Nuri dkk., 2024). Sistem peringkasan yang baik harus mampu mengelola tantangan ini dan menghasilkan ringkasan yang berdaya guna bagi pembaca (Setiawan & Alexander, 2023).

Dalam penelitian peringkasan, terdapat dua pendekatan utama: peringkasan ekstraktif dan peringkasan abstraktif. Peringkasan ekstraktif dilakukan dengan menyalin kalimat-kalimat penting dari dokumen asli (Pati & Rautray, 2024), sementara peringkasan abstraktif berusaha membangun kalimat baru berdasarkan pemahaman konteks (Widyassari dkk., 2022), yang secara alami lebih menyerupai hasil penulisan manusia. Peringkasan abstraktif dianggap lebih ideal karena memungkinkan sistem untuk merangkum informasi dari berbagai sumber tanpa sekadar mengulang kata-kata yang sama (Ay dkk., 2023). Namun, peringkasan abstraktif jauh lebih menantang dari sisi teknis karena membutuhkan pemahaman konteks dan kemampuan untuk menyusun informasi secara alami (Pramudi Ismi dkk., 2019).

Namun, penerapan peringkasan abstraktif pada bahasa Indonesia masih menghadapi berbagai tantangan. Kebanyakan penelitian sebelumnya, seperti yang dilakukan oleh Adelia dkk., (2019), menggunakan dataset berupa artikel jurnal dengan abstrak sebagai ringkasan. Meskipun penelitian tersebut menunjukkan bahwa penggunaan arsitektur *Bidirectional Gated Recurrent Unit* (BiGRU) untuk peringkasan abstraktif pada bahasa Indonesia dapat menghasilkan ringkasan dengan koherensi antar kalimat yang lebih baik dibandingkan metode ekstraktif, hasil tersebut masih terbatas pada teks dengan struktur yang lebih formal seperti jurnal ilmiah.

Selain itu, penelitian-penelitian sebelumnya pada peringkasan teks dalam bahasa Indonesia lebih banyak berfokus pada dokumen tunggal, seperti yang ditunjukkan oleh penelitian Lucky & Suhartono, (2022), yang menggunakan

dataset IndoSum untuk peringkasan artikel berita namun hanya mengandalkan peringkasan pada satu artikel. Pada kenyataannya, teks berita online sering kali tersebar dalam beberapa artikel yang saling berkaitan. Peringkasan multi-dokumen bertujuan untuk mengambil informasi utama dari berbagai sumber yang saling terkait, kemudian menggabungkannya menjadi sebuah ringkasan yang komprehensif dan tidak redundan.

Dalam peringkasan multi-dokumen Ranggianto dkk., (2023), tantangan utamanya adalah menyaring informasi yang relevan dari berbagai artikel berita untuk menghasilkan ringkasan yang tidak hanya singkat, tetapi juga menyampaikan inti dari berbagai sumber dengan cara yang koheren. Penelitian sebelumnya menunjukkan bahwa pendekatan abstraktif lebih unggul dalam hal koherensi antar kalimat dibandingkan dengan pendekatan ekstraktif yang cenderung menghasilkan ringkasan dengan informasi yang lebih terbatas dan terkadang kurang natural. Oleh karena itu, pendekatan abstraktif dinilai lebih menjanjikan, meskipun memiliki tingkat kesulitan yang lebih tinggi.

Model *deep learning* seperti BiGRU, yang telah terbukti efektif dalam peringkasan abstraktif pada bahasa Indonesia, perlu ditingkatkan untuk menangani tantangan dalam peringkasan multi-dokumen, di mana model harus dapat memahami konteks dari berbagai artikel terkait dan menggabungkannya menjadi ringkasan yang lebih holistik. Penelitian Suleiman & Awajan, (2020) menunjukkan bahwa arsitektur berbasis *recurrent neural networks* (RNN) dengan *attention mechanism* telah memberikan hasil yang cukup baik dalam peringkasan abstraktif,

tetapi masih ada ruang untuk perbaikan, terutama dalam menghadapi masalah seperti repetisi kalimat dan kesalahan informasi.

Kondisi ini mendorong kebutuhan akan sistem yang dapat membantu manusia mengelola informasi dengan efisien, salah satunya melalui teknologi peringkasan berita. Prinsip efisiensi dalam penyampaian informasi juga dapat dirujuk dari Al-Qur'an, sebagaimana Allah SWT berfirman:

مَا أَنزَلْنَا عَلَيْكَ الْقُرْآنَ لِتَشْقَىٰ

*“Dan Kami tidak menurunkan Al-Qur'an ini kepadamu (Muhammad) agar kamu menjadi susah” (Thaha:2).*

Ayat ini menerangkan bahwa turunnya Al-Qur'an bukanlah untuk menyusahkan sehingga penyampaian pesan juga seharusnya dilakukan dengan cara yang memudahkan penerima untuk memahami inti informasi (Departemen Agama Republik Indonesia, 2019). Al-Qurtubi menjelaskan tentang masuk Islamnya Umar bin al-Khattab, saat itu Umar bin al-Khattab masuk ke rumah iparnya Sa'id bin Zaid, ia sedang membaca Surah *Thaha* bersama isterinya Fatimah binti al-Khattab (adik Umar), dan Umar memintanya namun tidak diberikan sehingga ia marah dan merampas naskah tersebut. Ketika Umar membacanya, lunak dan lembutlah hatinya untuk menerima Islam. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem peringkasan berita yang tidak hanya akurat tetapi juga mudah dipahami oleh pembaca. Dengan merangkum inti dari artikel berita, penelitian ini diharapkan dapat membantu masyarakat memperoleh informasi yang benar dan relevan dengan lebih efisien.

Selain itu proses meringkas untuk mempermudah dalam menerima informasi juga bisa dirujuk dari HR Bukhori. Rasulullah *shallallahu 'alaihi wa sallam* bersabda,

بُعِثْتُ بِجَوَامِعِ الْكَلِمِ وَنُصِرْتُ بِالرُّعْبِ وَبَيَّنَّا أَنَا نَائِمٌ رَأَيْتُنِي أُتِيْتُ بِمَفَاتِيحِ خَزَائِنِ الْأَرْضِ فَوَضَعْتُ فِي يَدِي

*"Aku diutus dengan kalimat singkat yang padat makna, dan aku ditolong dengan rasa takut yang dihunjamkan dalam dada musuh-musuhku, dan ketika aku tidur, aku bermimpi diberi kunci-kunci perbendaharaan bumi lantas diletakkan di tanganku" (HR. Bukhori).*

Hadis ini mengajarkan pentingnya efisiensi dalam menyampaikan pesan, yang merupakan inti dari peringkasan teks. *Abstractive summarization* bertujuan untuk menyusun ulang dan memadatkan informasi dari dokumen panjang ke dalam format ringkas tanpa kehilangan esensi, mirip dengan cara Nabi menyampaikan ajaran yang kompleks dengan kata-kata sederhana (al-Bukhari, 2025).

Dengan latar belakang ini, penelitian ini bertujuan untuk mengembangkan model peringkasan abstraktif yang efektif untuk artikel berita berbahasa Indonesia. Fokus penelitian ini adalah pada pengembangan sistem yang mampu menyaring informasi relevan dari artikel berita dan menghasilkan ringkasan yang kohesif, akurat, dan informatif. Penelitian ini diharapkan dapat memberikan kontribusi penting dalam pengembangan teknologi peringkasan berita untuk bahasa Indonesia, sekaligus mengatasi tantangan dalam menciptakan model peringkasan yang adaptif terhadap karakteristik berita *online*.

## 1.2 Pernyataan Masalah

Berdasarkan latar belakang diatas maka pernyataan masalah bisa diuraikan dalam beberapa poin :

- a. Bagaimana cara memperbaiki peringkasan teks berbahasa Indonesia pada peringkasan ekstraktif yang cenderung menghasilkan ringkasan dengan kohesi dan hubungan antar kalimat yang kurang alami ?
- b. Bagaimana cara mengembangkan model peringkasan abstraktif untuk bahasa Indonesia ?

### **1.3 Tujuan Penelitian**

Berdasarkan latar belakang dan pernyataan masalah yang telah diuraikan, tujuan penelitian ini adalah :

- a. Menggunakan pendekatan peringkasan abstraktif untuk mengatasi kohesi dan hubungan antar kalimat yang kurang alami.
- b. Mengeksplorasi bagaimana arsitektur RNN dapat mengintegrasikan informasi dari berbagai bagian teks, dengan mempertimbangkan konteks dan relevansi setiap informasi, sehingga ringkasan yang dihasilkan tidak hanya singkat tetapi juga informatif dan terorganisir.

### **1.4 Batasan Penelitian**

Penelitian ini hanya akan membahas peringkasan abstraktif pada teks berita berbahasa Indonesia yang berasal dari berbagai sumber. Penelitian ini akan menggunakan arsitektur RNN untuk mengembangkan model peringkasan abstraktif. Penelitian ini akan menggunakan dataset yang terdiri dari artikel berita berbahasa Indonesia yang diperoleh dari berbagai sumber media online. Penelitian ini akan mengevaluasi kualitas ringkasan yang dihasilkan berdasarkan kohesi antar kalimat dan koherensi secara keseluruhan. Metrik evaluasi yang digunakan meliputi

ROUGE dan evaluasi subjektif oleh manusia untuk menilai kualitas ringkasan dalam hal kelengkapan informasi dan kesesuaian dengan konteks asli.

### **1.5 Manfaat Penelitian**

Hasil penelitian ini diharapkan dapat menghasilkan sistem peringkasan teks berbahasa Indonesia yang lebih koheren dan alami, serta menawarkan solusi efektif untuk mengintegrasikan informasi dari berbagai sumber dengan cara yang lebih terstruktur dan kontekstual. Selain itu, penelitian ini diharapkan dapat memperdalam pemahaman mengenai penerapan arsitektur RNN dalam tugas peringkasan teks. Dengan mengoptimalkan arsitektur berbasis RNN untuk konteks bahasa Indonesia, penelitian ini berpotensi menjadi landasan untuk pengembangan metode peringkasan yang lebih canggih dan efisien di masa depan.



## **BAB II**

### **STUDI PUSTAKA**

Bab ini membahas landasan teori yang mendasari penelitian mengenai abstractive text summarization dengan pendekatan *Recurrent Neural Network* (RNN), khususnya menggunakan arsitektur *Long Short-Term Memory* (LSTM) dan Bidirectional Gated Recurrent Unit (BiGRU). Kajian pustaka ini mencakup

#### **2.1 Peringkasan Abstraktif dalam Bahasa Indonesia**

*Abstractive Text Summarization* merupakan pendekatan yang bertujuan untuk menghasilkan ringkasan baru dengan memahami makna dan konteks dari sumber teks, berbeda dengan ekstraktif yang hanya mengambil kalimat-kalimat penting secara langsung. Pendekatan ini memungkinkan model untuk menghasilkan kalimat yang lebih koheren dan relevan, menciptakan ringkasan yang tidak hanya singkat tetapi juga informatif dan dapat memberikan wawasan yang lebih mendalam tentang isi dokumen asli.

Penerapan peringkasan abstraktif untuk berita Bahasa Indonesia juga telah diusulkan melalui pemanfaatan Abstract Meaning Representation (AMR). AMR mengandalkan struktur predikat-argumen untuk menciptakan ringkasan yang lebih koheren, dan meskipun awalnya diterapkan pada dokumen bahasa Inggris, teknik ini telah diadaptasi untuk Bahasa Indonesia. AMR ini digunakan untuk merangkum berita multi-dokumen dengan metode klusterisasi hirarkis untuk memilih kalimat-kalimat utama yang akan diringkas. Hasil eksperimen menunjukkan bahwa metode ini berhasil mencapai skor ROUGE-1 dan ROUGE-2 yang cukup tinggi,

menjadikannya salah satu metode abstraktif yang efektif dalam menghadirkan ringkasan berita yang kohesif dan dapat dimengerti oleh pembaca (Severina & Khodra, 2019).

Di sisi lain, metode *Dual Encoding* yang berbasis pada *Gated Recurrent Unit* (GRU) telah diterapkan dalam penelitian peringkasan teks Bahasa Indonesia. Pendekatan ini menggunakan teknik abstraktif dengan konsep-konsep yang menyerupai pemahaman manusia. Pada penelitian ini, model diuji menggunakan *K-Fold Cross Validation* dan mendapatkan skor ROUGE yang cukup baik, yang menunjukkan kemampuan model untuk menghasilkan ringkasan yang koheren dan mendekati cara manusia menyarikan informasi (Laksana dkk., 2022). Pendekatan ini bertujuan untuk menghadirkan alat peringkas otomatis yang mampu mempercepat proses penerimaan informasi oleh pembaca, terutama di tengah pertumbuhan volume berita yang cukup besar di internet.

## 2.2 Pentingnya Peringkasan Text

Ringkasan dari teks yang panjang dapat mempermudah pembaca dalam memahami inti teks tersebut dan system peringkasan text akan mengurangi beban kognitif dan waktu yang diperlukan untuk memahami suatu artikel dapat dikurangi tanpa menghilangkan konteks penting dari isi dokumen. Pendekatan hybrid menggabungkan keunggulan dari peringkasan model ekstraktif dan abstraktif dengan memanfaatkan algoritma *Textrank* sebagai ekstraktor informasi dan arsitektur *Transformer* sebagai generator ringkasan abstraktif. Efektivitas sistem biasanya diukur dengan metrik ROUGE yang membandingkan kesamaan n-gram antara ringkasan model dan ringkasan referensi. Hasil penelitian menunjukkan

performa model pada ROUGE-1 sebesar 0.34, ROUGE-2 sebesar 0.15, dan ROUGE-L sebesar 0.25 (Raihanunnisa dkk., 2023).

Pendekatan *extractive summarization* bekerja dengan memilih kalimat paling representatif dari dokumen asli berdasarkan bobot dan tingkat relevansinya. Proses ini biasanya diawali dengan tahapan *text preprocessing* seperti pembersihan teks, penghilangan *stopword*, dan *tokenisasi*, lalu dilanjutkan dengan pembobotan kata serta pemeringkatan kalimat. Teknik ini sering diimplementasikan menggunakan *library Python* seperti *Gensim* dan *NLTK* untuk menghasilkan ringkasan yang padat namun tetap mencerminkan isi utama dokumen. Evaluasi kualitas ringkasan umumnya dilakukan dengan membandingkan hasil sistem dengan ringkasan buatan manusia. Pada salah satu penelitian, pendekatan ini menunjukkan tingkat akurasi sebesar 72,6%, menegaskan bahwa metode ekstraktif cukup efektif dalam menyajikan informasi penting secara ringkas (Yanuarti & Alfaruq, 2022).

Peringkasan teks menjadi penting karena jumlah informasi digital yang terus bertambah membuat pembaca kesulitan untuk menyaring dan memahami isi dokumen secara menyeluruh dalam waktu terbatas. Sistem peringkasan otomatis dapat membantu mengurangi beban kognitif dengan menghadirkan ringkasan yang tetap mempertahankan konteks inti dari dokumen sumber. Dengan demikian, baik dalam bidang akademik, bisnis, jurnalistik, maupun media digital, peringkasan teks berfungsi sebagai alat yang esensial untuk mempercepat pemahaman informasi tanpa mengorbankan substansi. Teknik peringkasan, termasuk ekstraktif, abstraktif, dan *hybrid*, berperan penting dalam mendukung kebutuhan ini, sehingga menjadi salah satu fokus utama dalam pengembangan teknologi pemrosesan bahasa alami.

### 2.3 RNN

RNN telah menjadi arsitektur yang sangat relevan dalam tugas peringkasan teks, khususnya dalam pendekatan *abstractive text summarization*. RNN dirancang untuk memproses urutan data, yang memungkinkan model untuk menangkap hubungan antar kata atau kalimat dalam teks yang lebih panjang. Peringkasan abstraktif menggunakan RNN bertujuan untuk menghasilkan ringkasan yang tidak hanya mengulang kalimat dari dokumen sumber, tetapi juga membangun kalimat baru yang menyarikan informasi penting dengan cara yang lebih alami. Meskipun RNN standar dapat mengalami masalah *vanishing gradient*, varian seperti *Long Short-Term Memory* (LSTM) dan GRU mengatasi tantangan ini dengan lebih efektif, sehingga meningkatkan performa dalam memahami konteks teks yang lebih kompleks (Yaswanth dkk., 2023).

### 2.4 LSTM

LSTM adalah jenis arsitektur jaringan saraf yang dirancang untuk menangani masalah *vanishing gradient* pada RNN, memungkinkan model untuk mengingat informasi dalam jangka panjang dan sangat efektif dalam memproses urutan data, seperti teks. Dalam beberapa tahun terakhir, peringkasan teks telah menjadi tantangan besar dalam pemrosesan bahasa alami dan pembelajaran mendalam. Untuk menangani tantangan ini, penggunaan *Bi-directional* RNN dengan LSTM pada lapisan *encoding* dan model perhatian pada lapisan *decoding* terbukti efektif dalam menghasilkan ringkasan abstraktif yang lancar dan ringkas. Hal ini terbukti

dalam penerapan model *sequence-to-sequence* yang berhasil mengurangi kehilangan pelatihan dan meningkatkan efisiensi peringkasan, seperti yang terlihat dalam eksperimen untuk merangkum ulasan *Amazon Fine Food* (Mohammad Masum dkk., 2019).

Penelitian ini Faisal dkk., (2024) bertujuan untuk mengembangkan model peringkasan ekstraktif lanjutan untuk teks bahasa Indonesia menggunakan jaringan LSTM. Proses penelitian ini mencakup beberapa langkah kunci, praproses data teks, ekstraksi fitur menggunakan *Word2Vec*, pelatihan model LSTM, dan evaluasi ringkasan yang dihasilkan menggunakan metrik ROUGE-1. Model LSTM dioptimalkan dengan laju pembelajaran 0,001 dan dilatih selama 30–50 epoch. Hasil penelitian menunjukkan bahwa model LSTM mencapai kinerja superior dalam menghasilkan ringkasan yang koheren dan informatif, dengan akurasi tertinggi 0,88 yang tercapai pada laju pembelajaran 0,001 dan 50 epoch. Evaluasi berdasarkan metrik ROUGE-1 menunjukkan bahwa model ini dapat menghasilkan ringkasan dengan F-measure tinggi 0,875, yang menyoroti efektivitasnya dalam peringkasan teks otomatis. Penelitian ini menekankan potensi besar model berbasis LSTM dalam meningkatkan peringkasan ekstraktif untuk artikel bahasa Indonesia, serta memberikan kontribusi signifikan dalam penerapan teknik pembelajaran mesin canggih untuk mengatasi tantangan kelebihan informasi.

## 2.5 BIGRU

GRU adalah salah satu jenis arsitektur dalam RNN yang dirancang untuk mengatasi masalah *vanishing gradient*, yang sering terjadi pada model RNN tradisional. GRU menggabungkan dua komponen penting, yaitu *update gate* dan

*reset gate*, yang membantu model untuk memutuskan informasi mana yang harus diingat dan mana yang harus dilupakan. Dengan mekanisme ini, GRU lebih efisien dalam memproses informasi sekuensial dalam teks dan dapat menjaga kohesi antar kalimat dalam peringkasan teks abstraktif.

Pada penelitian ini Adelia dkk., (2019), penggunaan GRU dua arah BiGRU dengan mekanisme *attention mechanism* diterapkan untuk meningkatkan kualitas peringkasan teks abstraktif dalam Bahasa Indonesia. Dengan mempertimbangkan konteks dari kata-kata yang ada di sekitar teks, BiGRU dapat menghasilkan ringkasan yang lebih kohesif dan alami dibandingkan dengan pendekatan ekstraktif yang cenderung menghasilkan ringkasan yang terbatas dan kurang koheren. Evaluasi terhadap dataset dokumen jurnal berbahasa Indonesia menunjukkan bahwa model ini mampu menyarikan isi keseluruhan teks dengan menghasilkan ringkasan yang memiliki kesamaan tinggi dengan abstrak yang disediakan, meskipun masih terdapat tantangan terkait ukuran teks sumber dan faktor linguistik dalam Bahasa Indonesia.

## **2.6 Tabel Penelitian Terdahulu**

Tabel berikut menyajikan ringkasan dari beberapa penelitian terdahulu yang berkaitan dengan topik peringkasan teks, dengan fokus pada penggunaan model deep learning dan teknik-teknik terkait dalam peringkasan teks abstraktif. Tabel ini memberikan gambaran mengenai metodologi yang digunakan, dataset yang diterapkan, serta hasil yang dicapai oleh masing-masing penelitian.

Beberapa penelitian yang juga menggabungkan 2 pendekatan yakni pendekatan secara ekstraktif kemudian ringkasan tersebut dijadikan sebagai input dari model peringkasan abstraktif.

Tabel 2. 1 Tabel Review

No	Peneliti	Dataset	Metode	Hasil
1	(Dewi & Widiastuti, 2022)	Dokumen B. Indonesia	SVM, LSTM	Menghasilkan rancangan sistem
2	(Liu dkk., 2021)	Dokumen B. Cina	TextRank, KEDBS	Rouge-1 Score peringkasan ekstraktif = 0,369, Peringkasan abstractive = 0,24
3	(Laksana dkk., 2022)	Indosum	Bi-GRU, GRU	Hasil pengujian tersebut menghasilkan nilai R-1, R-2, R-L sebesar 0.3387776, 0.2395176, dan 0.3077376.
4	(Lucky & Suhartono, 2022)	Indosum	IndoBERT	Hasil evaluasi menunjukkan bahwa model dengan ukuran embedding yang lebih besar dan menggunakan decoder mirip Generative Pre-Training (GPT) dapat meningkatkan skor ROUGE dan BERTScore dari hasil model.
5	(Bahari & Dewi, 2024)	Indosum	Transformer	Performa peringkasan teks abstraktif diukur menggunakan ROUGE, skor tertinggi dicapai oleh T5-id dengan ROUGE-1 sebesar 0.61 dan ROUGE-2 sebesar 0.51
6	(Adelia dkk., 2019)	Jurnal bahasa Indonesia	Bi-GRU	ROUGE-1 0.11975, diskenario pertama
7	(Astuti dkk., 2024)	Dokumen B. Indonesia	MBART	Metode evaluasi menggunakan ROUGE menunjukkan nilai yang lebih baik dengan ROUGE-1 sebesar 35,94, ROUGE-2 sebesar 16,43, dan ROUGE-L sebesar 29,91.
8	(Khasanah & Hayaty, 2023)	Indosum	GPT2	Hasil penelitian mendapatkan hasil rata-rata recall untuk R-1, R-2, dan R-L berturut-turut adalah 0,61, 0,51, dan 0,57.
9	(Mohammad Masum dkk., 2019)	Dokumen B. Inggris	LSTM	Mengurangi training loss sebesar 0,036
10	(Hartawan dkk., 2024)	Dokumen B. Indonesia	BART	Nilai ROUGE-1 sebesar 37,19

Penelitian mengenai *automatic text summarization* menekankan pentingnya penyajian informasi secara cepat tanpa harus membaca keseluruhan teks, sehingga pembaca dapat menghemat waktu dan memperoleh pemahaman inti secara efisien. Dua pendekatan utama yang umum digunakan adalah metode ekstraktif dan abstraktif. Pendekatan abstraktif berupaya menghasilkan kalimat baru yang merepresentasikan esensi dokumen sebagaimana manusia meringkas teks, sehingga lebih fleksibel dan natural dibandingkan metode ekstraktif yang hanya memilih kalimat paling relevan. Dalam penelitian tersebut, penulis mengembangkan model peringkasan abstraktif berbasis metode Dual Encoding dengan memanfaatkan arsitektur *Gated Recurrent Unit* (GRU).

Evaluasi kinerja dilakukan menggunakan skema K-Fold Cross Validation sebanyak 5 lipatan, menghasilkan nilai ROUGE-1, ROUGE-2, dan ROUGE-L masing-masing sebesar 0.2128, 0.1199, dan 0.1881. Ketika diuji pada data baru, performa model meningkat dengan skor ROUGE-1 sebesar 0.3388, ROUGE-2 sebesar 0.2395, dan ROUGE-L sebesar 0.3077, yang menunjukkan bahwa pendekatan *Dual Encoding* berbasis GRU memiliki kemampuan generalisasi yang cukup baik dalam menghasilkan ringkasan yang relevan dan informatif (Laksana dkk., 2022).

Dalam penelitian lain, peringkasan teks didefinisikan sebagai proses mereduksi dokumen dengan menghilangkan informasi yang kurang relevan agar pembaca dapat memperoleh inti informasi secara cepat dan tepat. Kajian peringkasan abstraktif berbahasa Indonesia selama ini lebih banyak berfokus pada *multi-document summarization*, sehingga sejumlah metode yang dikembangkan



tidak sepenuhnya optimal ketika diterapkan pada tugas *single-document summarization*. Mengingat sebagian besar dataset dan penelitian berbahasa Inggris cenderung menitikberatkan pada peringkasan satu dokumen, studi ini memberikan perhatian khusus pada pengembangan model abstraktif untuk bahasa Indonesia menggunakan pendekatan *single-document*.

Penelitian tersebut memanfaatkan ketersediaan *Indonesian BERT* sebagai *encoder*, sejalan dengan tren penelitian berbahasa Inggris yang mengandalkan model BERT dalam peringkasan abstraktif. Eksperimen dilakukan menggunakan dataset IndoSum melalui arsitektur BERTSum dengan berbagai variasi ukuran embedding, kombinasi encoder, serta tipe decoder. Hasil evaluasi menunjukkan bahwa model dengan ukuran embedding lebih besar dan penggunaan decoder bergaya GPT mampu meningkatkan nilai ROUGE maupun BERTScore, mengindikasikan bahwa kapasitas representasi yang lebih tinggi dan pendekatan generatif pada decoder dapat meningkatkan kualitas ringkasan untuk teks berbahasa Indonesia.

Penelitian lain yang berfokus pada peringkasan teks bahasa Indonesia menunjukkan bahwa model berbasis Long Short-Term Memory (LSTM) juga mampu memberikan kontribusi signifikan, khususnya pada pendekatan ekstraktif. Dengan meningkatnya jumlah artikel daring setiap hari, kebutuhan akan mekanisme penyaringan informasi yang lebih efisien menjadi semakin penting. Dalam konteks ini, LSTM dimanfaatkan untuk memproses representasi teks yang telah diekstraksi menggunakan Word2Vec, sehingga model dapat mengenali pola-pola semantik yang relevan dalam dokumen. Pelatihan dilakukan menggunakan

konfigurasi *learning rate* kecil dan jumlah epoch yang cukup besar untuk memastikan stabilitas pembelajaran (Faisal dkk., 2024).

Hasil pengujian menunjukkan bahwa model LSTM dapat menghasilkan ringkasan yang koheren dan tetap mempertahankan informasi penting dari teks asli. Evaluasi dengan metrik ROUGE-1 menghasilkan nilai F-measure yang tinggi, menandakan kemampuan model dalam menangkap kata-kata kunci secara presisi dan recall yang baik. Temuan ini menguatkan pandangan bahwa metode berbasis RNN, termasuk LSTM, memiliki potensi yang kuat dalam mendukung pengembangan sistem peringkasan teks otomatis di bahasa Indonesia—baik sebagai pendekatan stand-alone maupun sebagai komponen dalam model hybrid yang menggabungkan teknik ekstraktif dan abstraktif.

Sebagai pelengkap dari berbagai pendekatan sebelumnya, penelitian lain menyoroti pentingnya peringkasan dokumen berita dalam konteks ledakan informasi yang terus meningkat. Dengan jumlah artikel yang bertambah setiap hari, kemampuan untuk merangkum berita secara efisien menjadi kebutuhan mendesak agar pembaca dapat memperoleh informasi relevan tanpa harus membaca seluruh dokumen. Dalam kerangka tersebut, pendekatan berbasis Recurrent Neural Network (RNN), khususnya arsitektur Long Short-Term Memory (LSTM), digunakan untuk menangani tugas peringkasan multi-dokumen berbahasa Indonesia. Penelitian ini memanfaatkan dua varian Word2Vec CBOW dan Skip-gram sebagai metode ekstraksi fitur untuk merepresentasikan kata secara semantik sebelum diproses oleh model LSTM (Alfin dkk., 2024).

Hasil evaluasi menunjukkan bahwa kedua varian Word2Vec memberikan performa yang cukup kompetitif, meskipun dengan perbedaan karakteristik. Model LSTM yang memanfaatkan CBOW menunjukkan nilai recall, presisi, dan F-measure masing-masing sebesar 0.487, 0.704, dan 0.550, yang menandakan kecenderungan CBOW dalam menangkap konteks umum secara lebih stabil. Sementara itu, pendekatan berbasis Skip-gram menghasilkan recall 0.414, presisi 0.687, dan F-measure 0.504, menunjukkan bahwa model ini lebih sensitif terhadap representasi kata yang jarang muncul namun tetap memberikan performa yang baik secara keseluruhan. Temuan tersebut memperkuat posisi RNN dan teknik word embedding dalam pengembangan sistem peringkasan berita Bahasa Indonesia, terutama pada skenario multi-dokumen yang memerlukan pemahaman konteks lintas paragraf.

Salah satu penelitian internasional telah menunjukkan bahwa arsitektur Recurrent Neural Network, khususnya Bidirectional Gated Recurrent Unit (BiGRU), memberikan hasil yang menjanjikan untuk tugas peringkasan abstraktif pada teks berbahasa Inggris dan Tionghoa. Keunggulan utama BiGRU terletak pada kemampuannya memanfaatkan konteks dua arah, baik sebelum maupun sesudah kata, sehingga model dapat memahami hubungan antarbagian teks secara lebih komprehensif. Pendekatan ini menjadi relevan bagi Bahasa Indonesia, terutama karena berbagai riset sebelumnya masih didominasi metode ekstraktif yang menghasilkan ringkasan dengan keterhubungan kalimat yang rendah (Adelia dkk., 2019).

Ketika pendekatan BiGRU mulai diterapkan pada dokumen berbahasa Indonesia, hasilnya menunjukkan peningkatan kualitas ringkasan secara signifikan. Evaluasi menggunakan metrik ROUGE menunjukkan tingkat kemiripan yang tinggi antara ringkasan yang dihasilkan model dan abstrak referensi, menandakan bahwa model mampu menangkap struktur dan inti informasi dengan baik. Temuan ini mempertegas bahwa peringkasan abstraktif berbasis RNN bukan hanya menjadi alternatif atas keterbatasan model ekstraktif sebelumnya, tetapi juga membuka arah pengembangan baru dalam upaya menghasilkan ringkasan Bahasa Indonesia yang lebih informatif, koheren, dan mendekati gaya penulisan manusia

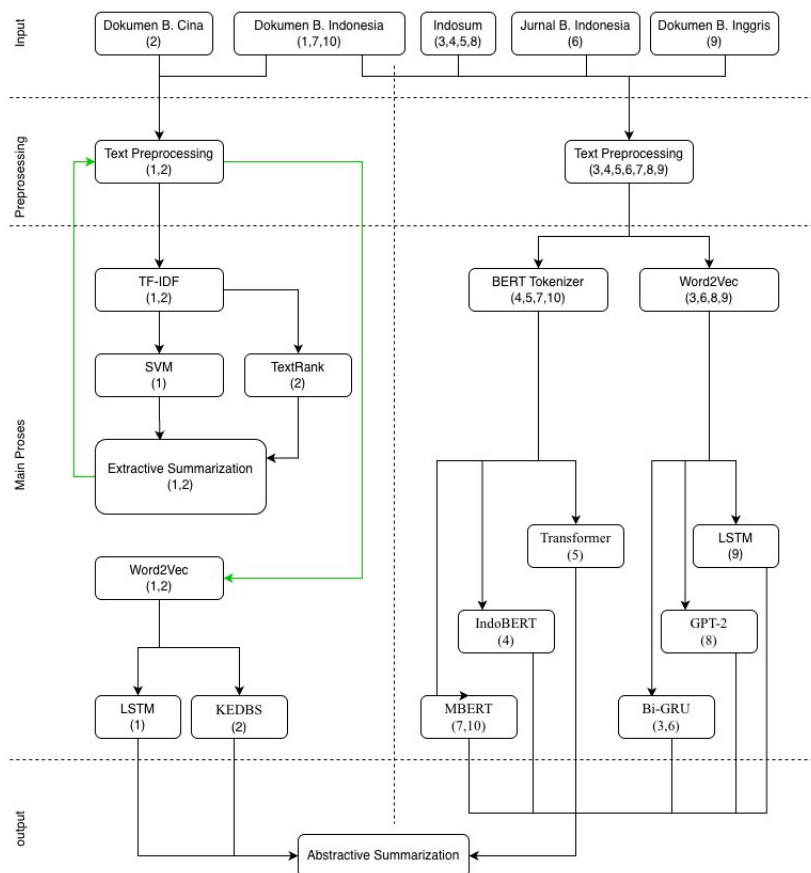
Penelitian-penelitian terbaru menunjukkan bahwa model berbasis Transformer, seperti BERT, BERTSum, dan model dekoder GPT-like, telah memberikan kinerja yang sangat baik dalam tugas peringkasan teks, termasuk pada Bahasa Indonesia. Keunggulan Transformer terutama berasal dari kemampuannya memahami konteks global secara paralel serta menghasilkan ringkasan yang lebih natural dan informatif. Namun demikian, tinjauan literatur juga mengungkap bahwa pendekatan berbasis Recurrent Neural Network (RNN), khususnya arsitektur LSTM dan BiGRU, masih memiliki potensi yang sangat menarik untuk terus dikembangkan.

Hal ini karena RNN mampu menangkap urutan dan alur kalimat secara lebih eksplisit, yang menjadi aspek penting dalam menghasilkan ringkasan yang koheren. Sejumlah penelitian menunjukkan bahwa LSTM dan BiGRU tetap kompetitif, terutama pada skenario sumber daya terbatas dan ketika fokus penelitian adalah pada pemanfaatan representasi sekuensial yang mendalam. Dengan demikian,

meskipun Transformer mendominasi lanskap penelitian modern, pengembangan metode berbasis RNN tetap relevan dan menjanjikan sebagai arah penelitian lanjutan dalam peringkasan teks Bahasa Indonesia.

## 2.7 Kerangka Teori

Penelitian ini didukung oleh konsep-konsep yang merujuk pada literatur ilmiah terkait peringkasan teks, yang dijelaskan secara rinci dalam Gambar 2.1. Kerangka teori ini menyusun beberapa penelitian sebelumnya yang berkaitan dengan penerapan model *deep learning* dalam peringkasan teks, terutama teks berbahasa Indonesia.



Gambar 2.1 Kerangka Teori

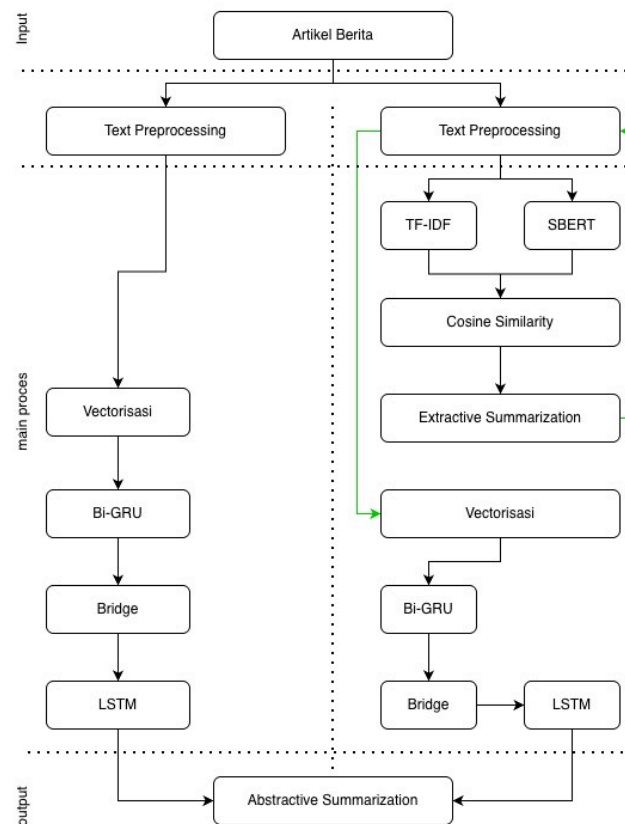
## BAB III

### METODOLOGI PENELITIAN

Bab ini menjelaskan metodologi yang digunakan dalam pengembangan model *abstractive text summarization* berbasis LSTM dan BiGRU. Metodologi disusun untuk menggambarkan alur penelitian mulai dari pengumpulan , *preprocessing* data hingga perancangan serta pelatihan model.

#### 3.1 Kerangka Konsep

Kerangka konsep pada penelitian ini akan digambarkan pada Gambar 3.1. Tahapan terdiri dari input, *preprocessing*, main process, dan output.



Gambar 3.1 Kerangka Konsep

Kerangka konsep ini menggambarkan proses dua tahap dalam sistem ringkasan abstraktif yaitu, peringkasan abstraktif yang menggunakan ekstraktif sebagai *input* dan peringkasan abstraktif yang langsung menggunakan artikel sebagai *input*. Pada tahap pertama, input berupa Artikel Berita diolah melalui serangkaian langkah *preprocessing* yang mencakup *Case Folding*, *Sentence Tokenization*, dan *Word Tokenization*. Hasil pra-pemrosesan kemudian diproses lebih lanjut melalui dua metode utama: TF-IDF dan S-BERT, yang keduanya digunakan untuk menghitung kemiripan kosinus (*Cosine Similarity*) antar kalimat dengan judul. Berdasarkan perhitungan kemiripan ini, sistem akan memilih kalimat-kalimat paling representatif untuk menghasilkan *Extractive Summarization*.

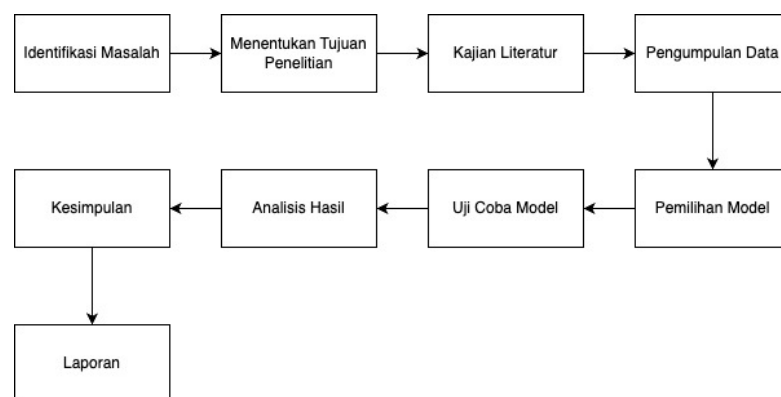
Peringkasan abstraktif yang telah dihasilkan, bersama dengan *Gold Summary* (ringkasan referensi yang dibuat manusia), digunakan sebagai input untuk model pembelajaran mendalam. Dalam arsitektur ini, Bi-GRU berperan sebagai encoder yang bertugas mengekstraksi fitur dan representasi kontekstual dari teks input (baik ringkasan ekstraktif maupun *gold summary*). Hasil encoding kemudian dilewatkan ke komponen Bridge, yang berfungsi sebagai penghubung atau transformasi antara encoder dan decoder. Selanjutnya, LSTM berperan sebagai decoder yang menggunakan representasi yang telah diproses oleh Bridge untuk menghasilkan ringkasan baru secara generatif, yaitu dalam bentuk *Abstractive Summarization*.

Pada tahap kedua, menggunakan artikel murni untuk dijadikan sebagai inputan. Proses yang dilakukan sama seperti tahap pertama setelah berhasil mendapatkan peringkasan ekstraktif, Yaitu *encode* menggunakan Bi-GRU dan di

*decode menggunakan LSTM*. Sistem ini menggabungkan kekuatan Bi-GRU dalam pemahaman konteks, Bridge dalam integrasi informasi, dan LSTM dalam generasi teks koheren untuk menghasilkan ringkasan yang tidak hanya informatif tetapi juga alami seperti buatan manusia.

### 3.2 Design Penelitian

Desain penelitian merupakan kerangka sistematis yang digunakan untuk mengarahkan proses penelitian agar sesuai dengan tujuan yang telah ditetapkan. Dalam penelitian ini, desain penelitian disusun untuk menggambarkan alur kerja pengembangan model peringkasan teks abstraktif berbasis RNN (LSTM dan BiGRU) pada dokumen berbahasa Indonesia. Tahapan yang disertakan meliputi pengumpulan data, preprocessing, perancangan model, pelatihan, hingga evaluasi menggunakan metrik ROUGE. Setiap tahap dirancang untuk memastikan penelitian berjalan terstruktur dan menghasilkan model peringkasan yang efektif.



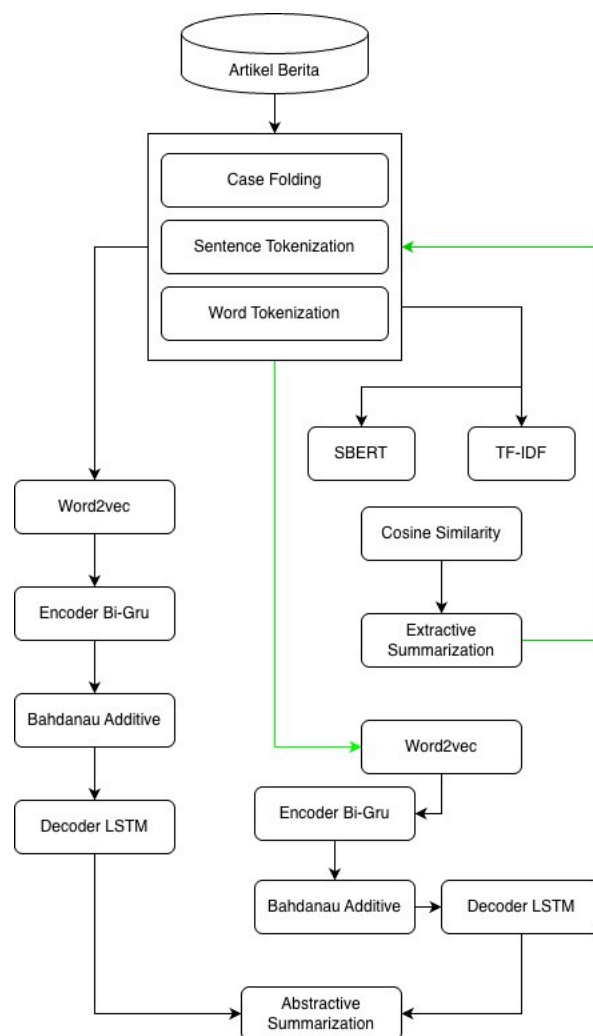
Gambar 3.2 Design Penelitian

Gambar 3.2 menyajikan desain penelitian secara visual untuk memperjelas alur penelitian yang dilakukan. Dengan demikian, desain penelitian ini menjadi dasar utama dalam mencapai hasil yang konsisten dan dapat dipertanggungjawabkan.



### 3.3 Design Sistem

Design sistem ini mencakup beberapa tahapan utama untuk menghasilkan model peringkasan abstraktif dari artikel berita berbahasa Indonesia. Perhatikan Gambar 3.3.



Gambar 3.3 Design Sistem

Desain sistem ini menggambarkan alur pengolahan data hingga terbentuknya model peringkasan abstraktif berbasis arsitektur RNN dengan kombinasi encoder BiGRU dan decoder LSTM. Proses dimulai dari artikel berita berbahasa Indonesia

yang terlebih dahulu melalui tahap preprosesing, seperti *case folding*, tokenisasi, agar teks berada dalam format yang konsisten. Teks yang telah diproses kemudian direpresentasikan melalui dua pendekatan, yaitu TF-IDF sebagai representasi berbasis bobot kata, dan SBERT sebagai representasi semantik berbasis *sentence embedding*. Kedua representasi ini dievaluasi menggunakan cosine similarity untuk menilai relevansi antar kalimat sehingga diperoleh ringkasan ekstraktif yang berfungsi sebagai *candidate summary*. Ringkasan ekstraktif tersebut digunakan sebagai *source* dalam penyusunan data latih, sedangkan *gold summary* atau ringkasan asli artikel digunakan sebagai *target*.

Tahap berikutnya adalah proses peringkasan abstraktif menggunakan arsitektur RNN dengan bentuk implementasi *sequence-to-sequence*. Pada tahap ini, ringkasan ekstraktif terlebih dahulu diproses oleh *encoder* BiGRU yang bekerja dua arah untuk menangkap konteks kalimat secara lebih menyeluruh. Hasil *encoding* kemudian diteruskan ke lapisan *bridge* yang menyesuaikan dimensi dan memfasilitasi penyelarasan konteks sebelum diteruskan ke *decoder*. *Decoder* menggunakan LSTM yang dilengkapi mekanisme *attention* agar dapat memberikan fokus pada bagian-bagian *input* yang paling relevan ketika menghasilkan setiap *token* ringkasan. Melalui tahapan ini, sistem menghasilkan ringkasan abstraktif yang tidak hanya menyalin kalimat sumber, tetapi membangun kembali informasi dalam bentuk yang lebih singkat, koheren, dan semantik.

### 3.4 Dataset

Penelitian ini menggunakan data yang diambil dari platform Kaggle, berupa kumpulan artikel berita dari berbagai media di Indonesia. Setiap data artikel

mencakup informasi mengenai sumber berita, judul, konten artikel, serta ringkasan. Artikel-artikel tersebut mencakup beragam topik, seperti politik, olahraga, pendidikan, dan lain-lain. Ringkasan yang tersedia merupakan ringkasan asli yang dibuat oleh ahli atau editor profesional dalam meringkas berita. Jumlah data yang digunakan dalam penelitian ini ditampilkan pada Tabel 3.1.

Tabel 3. 1 Tabel Dataset

Sumber Berita	Total Rows
cnn indonesia	6760
kumparan	2738
dailysocial.id	1629
antaranews	1579
merdeka	1306
juara.net	1222
suara	987
goal indonesia	856
poskotanews	781
rimanews	776

### 3.5 Preprocessing

*Preprocessing* merupakan serangkaian langkah awal yang dilakukan untuk membersihkan dan menyiapkan teks mentah agar lebih mudah diproses oleh model NLP. Tujuannya adalah mengurangi *noise*, menyeragamkan format teks, serta membentuk struktur data yang lebih terorganisir sehingga algoritma pemrosesan bahasa dapat bekerja secara lebih efektif. Menurut penelitian dalam bidang NLP, *preprocessing* membantu meningkatkan kualitas representasi teks dan berkontribusi pada performa model secara keseluruhan (Alasadi & Bhaya, 2017).

Dalam penelitian ini, *preprocessing* dilakukan untuk memastikan bahwa artikel berita memiliki format yang konsisten sebelum diproses lebih lanjut oleh

model peringkasan. Tahap ini mencakup beberapa teknik dasar, seperti *case folding*, tokenisasi kalimat, dan tokenisasi kata.

### 3.5.1 Case Folding

Tahap pertama adalah *case folding*, yaitu mengubah seluruh teks menjadi huruf kecil (*lowercasing*). Proses ini bertujuan untuk memastikan konsistensi data, karena huruf kapital dan huruf kecil dianggap sama dalam konteks analisis teks.

Tabel 3. 2 Contoh hasil Case Folding

Teks Asli	Hasil Case Folding
"Pemerintah Berjanji Akan Mengambil Langkah-Langkah Untuk Menekan Inflasi Agar Tidak Semakin Memberatkan."	"pemerintah berjanji akan mengambil langkah-langkah untuk menekan inflasi agar tidak semakin memberatkan."

### 3.5.2 Sentence Tokenization

Setelah teks diubah menjadi huruf kecil, langkah selanjutnya adalah tokenisasi kalimat. Dalam tahap ini, setiap paragraf teks dipecah menjadi kalimat-kalimat terpisah. Langkah ini memungkinkan setiap kalimat untuk dianalisis secara individual.

Tabel 3. 3 Contoh Hasil Tokenisasi Kalimat

Teks Setelah Lowercasing	Hasil Tokenisasi Kalimat
"pemerintah berjanji akan mengambil langkah-langkah untuk menekan inflasi agar tidak semakin memberatkan. masyarakat diharapkan mendukung upaya tersebut dengan melakukan penghematan. langkah-langkah strategis akan segera diumumkan."	["pemerintah berjanji akan mengambil langkah-langkah untuk menekan inflasi agar tidak semakin memberatkan.", "masyarakat diharapkan mendukung upaya tersebut dengan melakukan penghematan.", "langkah-langkah strategis akan segera diumumkan."]

### 3.5.3 Word Tokenization

Setelah kalimat-kalimat diperoleh, dilakukan *tokenisasi* kata, yaitu memecah setiap kalimat menjadi kata-kata terpisah. Proses ini memungkinkan setiap kata untuk diidentifikasi secara individual, yang nantinya bisa diproses lebih lanjut sesuai kebutuhan analisis.

Tabel 3. 4 Contoh Hasil Tokenisasi Kata

Hasil Tokenisasi Kalimat	Hasil Tokenisasi Kata
"pemerintah berjanji akan mengambil langkah-langkah untuk menekan inflasi agar tidak semakin memberatkan."	["pemerintah", "berjanji", "akan", "mengambil", "langkah-langkah", "untuk", "menekan", "inflasi", "agar", "tidak", "semakin", "memberatkan"]

Dengan tahapan *preprocessing* ini, teks menjadi lebih terstruktur dan siap untuk diolah lebih lanjut dalam proses peringkasan.

### 3.6 Peringkasan Ekstraktif

Setelah melalui tahap pra-pemrosesan data, dokumen teks yang telah bersih diproses ke dalam modul peringkasan ekstraktif. Pada tahap ini, setiap kalimat dalam dokumen akan dikonversi menjadi representasi vektor untuk dihitung bobot kepentingannya. Perancangan sistem ekstraktif ini terdiri dari tiga komponen utama: (1) Ekstraksi fitur statistik menggunakan TF-IDF, (2) Ekstraksi fitur semantik menggunakan model Deep Learning SBERT, dan (3) Mekanisme penilaian (*scoring*) yang menggabungkan kedua fitur tersebut menggunakan perhitungan Cosine Similarity dan akumulasi bobot. Kalimat-kalimat dengan skor tertinggi (Top-N) akan dipilih sebagai output tahap pertama yang selanjutnya menjadi input bagi model abstraktif.

Tabel 3. 5 Contoh Peringkasan Ekstraktif

No	Kalimat Asli (Artikel)	Terpilih Sebagai Ringkasan?
1	Pemerintah mengumumkan kebijakan baru untuk menstabilkan harga beras di pasaran.	✓
2	Kebijakan ini diambil setelah harga beras mengalami kenaikan signifikan dalam dua bulan terakhir.	✓
3	Selain itu, distribusi beras dari beberapa daerah penghasil mengalami keterlambatan akibat cuaca ekstrem.	✓
4	Para analis memperkirakan kebijakan ini dapat menekan harga dalam beberapa minggu ke depan.	✗
5	Namun, beberapa pedagang menilai bahwa kebijakan ini belum menyelesaikan masalah distribusi di lapangan.	✗

### 3.6.1 Ekstraksi Fitur

Ekstraksi fitur merupakan tahap penting dalam pemrosesan teks untuk mengubah data teks mentah menjadi representasi numerik yang dapat dipahami oleh algoritma komputasi (Khairunnisa dkk., 2021). Pada penelitian ini, digunakan dua pendekatan utama, yaitu Term Frequency–Inverse Document Frequency (TF-IDF) dan Sentence-BERT (SBERT). Kedua metode ini menghasilkan vektor representasi, tetapi dengan karakteristik dan tujuan yang berbeda.

#### a. Term Frequency-Inverse Document Frequency (TF-IDF)

TF-IDF merupakan metode ekstraksi fitur berbasis statistik yang digunakan untuk menentukan tingkat kepentingan suatu kata dalam sebuah dokumen relatif terhadap keseluruhan korpus. Nilai TF (Term Frequency) menggambarkan frekuensi kemunculan kata dalam dokumen, sedangkan IDF (Inverse Document Frequency) mengukur kelangkaan kata tersebut pada seluruh dokumen. Kombinasi keduanya menghasilkan skor TF-IDF yang menekankan kata-kata yang memiliki informasi relevan dan menurunkan bobot kata umum yang sering muncul, sehingga membantu meningkatkan kualitas representasi teks dalam berbagai tugas NLP (Indriati dkk., 2021).

Dalam penerapannya, seluruh kata unik dalam korpus dikumpulkan menjadi vocabulary, kemudian setiap dokumen direpresentasikan sebagai vektor berdasarkan bobot TF-IDF dari setiap kata tersebut. Proses ini menghasilkan matriks sparse berukuran jumlah dokumen  $\times$  jumlah vocab, dengan sebagian besar nilai nol, namun tetap efektif sebagai representasi baseline dalam analisis dokumen, pemeringkatan kalimat, maupun sistem peringkasan. Representasi TF-IDF tetap menjadi metode fundamental yang banyak digunakan karena sederhana, cepat, dan dapat memberikan performa kompetitif dalam berbagai skenario pemrosesan teks (Delibaş, 2025). Berikut penjelasan mengenai cara penghitungan menggunakan TF-IDF.

- Term Frequency (TF)

Term Frequency digunakan untuk mengukur seberapa sering sebuah kata muncul dalam sebuah dokumen. Semakin sering sebuah kata muncul, maka semakin besar nilai TF-nya. Rumus TF dapat dituliskan sebagai berikut:

$$TF(t, d) = \frac{f_{t,d}}{\sum_k f_{k,d}} \quad (3.1)$$

dengan:

$f_{t,d}$ : jumlah kemunculan kata  $t$  dalam dokumen  $d$   
 $\sum_k f_{k,d}$ : total seluruh kata dalam dokumen  $d$

Komponen ini menggambarkan **relevansi lokal** kata terhadap dokumen tertentu.

- Inverse Document Frequency (IDF)

Inverse Document Frequency berfungsi untuk memberi bobot lebih besar pada kata-kata yang jarang muncul di seluruh kumpulan dokumen. Kata yang sering

muncul di banyak dokumen dianggap kurang informatif, sehingga IDF-nya rendah.

Rumus IDF adalah:

$$IDF(t) = \log \left( \frac{N}{df_t} \right) \quad (3.2)$$

dengan:

- $N$ : jumlah total dokumen dalam corpus
- $df_t$ : jumlah dokumen yang mengandung kata  $t$

Semakin kecil nilai  $df_t$ , maka semakin besar bobot IDF, menandakan kata tersebut memiliki nilai informasi yang lebih tinggi dalam konteks corpus.

- Perhitungan Bobot TF-IDF

Nilai TF dan IDF dikombinasikan untuk menghasilkan **bobot TF-IDF**, yang menyatakan tingkat kepentingan kata  $t$  dalam dokumen  $d$  berdasarkan kemunculannya secara lokal dan distribusinya secara global.

$$TF-IDF(t, d) = TF(t, d) \times IDF(t) \quad (3.3)$$

Interpretasinya:

- TF tinggi + IDF tinggi  $\rightarrow$  kata sangat penting
- TF tinggi + IDF rendah  $\rightarrow$  kata umum, kurang informatif
- TF rendah + IDF tinggi  $\rightarrow$  kata jarang tetapi relevan
- TF rendah + IDF rendah  $\rightarrow$  kata tidak penting

Bobot TF-IDF inilah yang digunakan dalam penelitian ini sebagai representasi fitur awal sebelum proses pemilihan kalimat pada tahap extractive summarization.

#### b. *Sentence-BERT (SBERT)*

*Sentence-BERT* (SBERT) merupakan pengembangan dari arsitektur BERT yang dirancang khusus untuk menghasilkan representasi kalimat dalam bentuk dense vector yang kaya informasi semantik. Pada penelitian ini digunakan model



pre-trained paraphrase-multilingual-MiniLM, yaitu varian ringan dari Transformer yang telah dilatih menggunakan data multibahasa, sehingga mampu menangkap makna teks dalam Bahasa Indonesia. Model MiniLM ini dikembangkan melalui proses knowledge distillation, sehingga lebih efisien namun tetap mempertahankan kualitas pemahaman semantic (Wang dkk., 2020).

SBERT mengubah setiap kalimat atau dokumen menjadi vektor berdimensi tetap yang padat (dense vector representation). Berbeda dengan TF-IDF yang menghasilkan vektor sparse berbasis frekuensi kata, vektor SBERT menggambarkan hubungan makna antar kalimat, sehingga kalimat berbeda namun memiliki makna yang mirip akan berada dekat dalam ruang vektor (memiliki nilai cosine similarity tinggi). Kemampuan ini menjadikan SBERT sangat efektif untuk tugas-tugas yang memerlukan pemahaman semantik seperti peringkasan, pencarian semantik, dan pemeringkatan kalimat.

### 3.6.2 Penilaian

Penelitian ini mengadopsi pendekatan pemeringkatan kalimat berbasis *hybrid similarity* yang mengintegrasikan representasi statistik dan representasi semantik untuk mengukur relevansi setiap kalimat terhadap judul artikel. Pendekatan ini terinspirasi oleh perkembangan terbaru dalam penelitian embedding teks, di mana kombinasi antara model distribusional tradisional (seperti TF-IDF) dan representasi neural berbasis Transformer (seperti Sentence-BERT) terbukti dapat menangkap hubungan tekstual secara lebih komprehensif. Judul artikel diposisikan sebagai *anchor semantic reference* yang mencerminkan esensi topik utama dokumen,

sehingga tingkat kedekatan antara kalimat dan judul dianggap sebagai indikator penting bagi pemilihan kalimat kandidat ringkasan (Delibaş, 2025).

Pendekatan gabungan ini sejalan dengan tren penelitian terbaru yang menunjukkan bahwa mengombinasikan dua metode dengan karakteristik berbeda dapat meningkatkan efektivitas dan efisiensi proses peringkasan (UÇKAN, 2025). Jika beberapa studi sebelumnya mengintegrasikan model berbasis grafik dengan model bahasa besar (LLM) untuk meningkatkan akurasi dan mempercepat pemilihan kalimat penting, penelitian ini menerapkan prinsip serupa melalui penggabungan skor statistik TF-IDF dan representasi semantik SBERT. TF-IDF berfungsi menangkap kedekatan leksikal antara kalimat dan judul, sedangkan SBERT memberikan pemahaman semantik yang lebih mendalam terhadap struktur makna. Dengan mengombinasikan kedua pendekatan, penelitian ini bertujuan memperoleh ringkasan yang lebih relevan, stabil, dan efisien dibandingkan penggunaan satu metode secara tunggal.

#### **a. Penilaian Statistik (Cosine TF-IDF)**

Pada tahap statistik, skor untuk setiap kalimat dihitung berdasarkan kemiripan TF-IDF antara vektor TF-IDF judul dan vektor TF-IDF dari kalimat. Pertama, judul artikel diolah (preprocessing) kemudian dikonversi menjadi vektor TF-IDF menggunakan corpus yang sama dengan dokumen. Selanjutnya, setiap kalimat dari artikel juga direpresentasikan sebagai vektor TF-IDF. Kemiripan antara vektor kalimat dan vektor judul diukur menggunakan Cosine Similarity. Kalimat dengan skor similarity lebih tinggi dianggap lebih relevan secara statistik terhadap tema utama yang ditunjukkan judul.

### b. Penilaian Semantik(Cosine SBERT)

Pendekatan kedua menilai relevansi semantik dengan cara mengubah judul dan kalimat menjadi embedding melalui model **Sentence-BERT (SBERT)**. Judul diproses dan di-encode menjadi **vektor embedding padat**, begitu juga setiap kalimat dalam artikel. Kemudian, **Cosine Similarity** dihitung antara embedding kalimat dan embedding judul, untuk mengukur kedekatan makna di tingkat semantik. Dengan cara ini, kalimat yang tidak hanya memiliki kata sama, tetapi juga makna serupa dengan judul akan mendapatkan skor semantik tinggi.

### c. Penggabungan dan Seleksi

Setelah skor statistik dan skor semantik diperoleh, penelitian ini menggunakan pendekatan *score-level fusion* untuk menggabungkan keduanya menjadi satu nilai akhir. Pendekatan ini dipilih karena sederhana, efektif, dan banyak digunakan sebagai baseline dalam penelitian hybrid text similarity, termasuk pada studi HyEWCos (2025) yang menunjukkan bahwa penggabungan dua sumber representasi berbeda dapat memberikan hasil yang lebih stabil dibanding penggunaan satu metode saja (Hendry dkk., 2025). Pada tahap ini, skor TF-IDF dan skor SBERT dinormalisasi, kemudian digabungkan menggunakan pembobotan linear:

$$\text{Skor Akhir} = \alpha \cdot \text{Sim}_{\text{TFIDF}} + (1 - \alpha) \cdot \text{Sim}_{\text{SBERT}} \quad (3.4)$$

dengan nilai  $\alpha$  dapat ditetapkan sebagai bobot tetap atau ditentukan melalui eksperimen sederhana. Hasil skor akhir ini kemudian digunakan untuk melakukan pemeringkatan kalimat, di mana kalimat dengan skor tertinggi dipilih sebagai kandidat ringkasan (Kramer, 2024). Dengan mekanisme ini, kalimat yang baik

secara leksikal dan sekaligus kuat secara semantik memiliki peluang lebih besar untuk terpilih, sehingga menghasilkan ringkasan yang lebih informatif dan representatif.

### 3.7 Peringkasan Abstraktif

Peringkasan abstraktif bertujuan menghasilkan ringkasan baru yang tidak hanya mengambil kalimat dari teks asli, tetapi juga melakukan parafrase dan konstruksi ulang informasi. Pada penelitian ini digunakan arsitektur *sequence-to-sequence* (seq2seq) klasik berbasis *Encoder–Decoder*, yang masih menjadi fondasi utama dalam banyak model abstraktif modern sebelum munculnya model Transformer. Arsitektur ini dipilih karena sederhana, efisien, dan cukup kuat untuk menghasilkan representasi semantik dari dokumen pendek hingga menengah. Model terdiri dari empat komponen utama: *Encoder*, BRIDGE, *Decoder*, dan mekanisme pelatihan berbasis *teacher forcing*.

#### 3.7.1 Arsitektur Encoder-Decoder

Arsitektur *Encoder–Decoder* bekerja dengan mengubah urutan teks input menjadi representasi *vektor laten*, kemudian mendekodekan vektor tersebut menjadi teks ringkasan. *Encoder* bertugas menangkap informasi semantik dari seluruh dokumen, sementara *Decoder* menghasilkan teks baru berdasarkan vektor konteks yang diteruskan melalui mekanisme BRIDGE. Struktur seperti ini telah menjadi dasar dalam model peringkasan sejak era *Neural Machine Translation*, karena kemampuannya mempelajari hubungan antar-kata dalam urutan panjang. Pada penelitian ini, *Encoder* menggunakan **BiGRU**, sedangkan *Decoder*

menggunakan **LSTM**, sehingga kombinasi keduanya dapat menangkap pola informasi secara dua arah sekaligus menjaga stabilitas pada saat proses generasi output.

### 3.7.2 *Encoder BiGRU*

*Encoder* pada sistem ini diimplementasikan menggunakan ***Bidirectional Gated Recurrent Unit (BiGRU)***. BiGRU dipilih karena lebih ringan dibandingkan LSTM namun tetap memiliki kemampuan menangkap konteks jangka panjang dan mengurangi masalah *vanishing gradient*. Dengan struktur dua arah, BiGRU memproses kalimat dari kiri ke kanan (*forward pass*) dan dari kanan ke kiri (*backward pass*). Output dari kedua arah kemudian digabungkan untuk membentuk representasi konteks yang lebih kaya. Representasi akhir dari BiGRU inilah yang menjadi *context vector* awal sebelum diteruskan ke komponen BRIDGE. Pendekatan ini memastikan bahwa model memahami struktur semantik dokumen secara menyeluruh, bukan hanya berdasarkan urutan kata ke depan.

### 3.7.3 *Mekanisme Penghubung (BRIDGE)*

Pada model *seq2seq* klasik, dimensi keluaran *encoder* sering tidak cocok secara langsung dengan dimensi tersembunyi (*hidden size*) dari *decoder*. Untuk itu digunakan **BRIDGE**, yaitu lapisan penghubung berupa feed-forward layer atau transformasi linear untuk menjembatani perbedaan dimensi tersebut. BRIDGE mengambil *context vector* dari *encoder* kemudian memetakannya ke ruang representasi yang dibutuhkan oleh Decoder sebagai *initial hidden state*. Tanpa mekanisme ini, *decoder* tidak akan dapat memulai proses generasi secara stabil.

Selain itu, BRIDGE juga berperan sebagai ruang transformasi semantik yang membantu memampatkan informasi dari dokumen panjang ke dalam bentuk yang lebih padat dan siap digunakan pada tahap *decoding*.

#### 3.7.4 Decoder LSTM

*Decoder* yang digunakan dalam model ini adalah LSTM, yang terkenal karena kemampuannya mempertahankan informasi jangka panjang melalui mekanisme *cell state*. LSTM menerima *initial hidden state* dari BRIDGE dan bekerja menghasilkan token demi token menggunakan mekanisme *autoregressive*. Pada setiap langkah *decoding*, model memanfaatkan output sebelumnya, *hidden state*, dan informasi konteks untuk menghasilkan kata berikutnya. Kombinasi LSTM sebagai Decoder memberikan stabilitas dalam proses generasi kalimat, terutama pada teks berbahasa Indonesia yang memiliki variasi struktur sintaksis. Selama pelatihan, model memanfaatkan teknik *teacher forcing* untuk mempercepat konvergensi dan meningkatkan akurasi prediksi urutan.

### 3.8 Skenario Pengujian dan Evaluasi

Untuk memastikan bahwa model peringkasan abstraktif yang dikembangkan bekerja secara optimal dan sesuai dengan tujuan penelitian, diperlukan rancangan skenario pengujian yang terstruktur serta metode evaluasi yang terukur. Pada tahap ini, proses pengujian tidak hanya berfokus pada kinerja model dalam menghasilkan ringkasan, tetapi juga pada konsistensi lingkungan eksperimen dan pengaturan parameter pelatihan yang digunakan. Selain itu, evaluasi kuantitatif dilakukan

menggunakan metrik standar industri, yaitu ROUGE, untuk menilai tingkat kesesuaian antara ringkasan yang dihasilkan model dengan ringkasan referensi.

Skenario pengujian yang dirancang mencakup tiga aspek utama: **lingkungan pengujian**, yang meliputi spesifikasi perangkat keras dan perangkat lunak yang digunakan; **konfigurasi hyperparameter**, yang menentukan perilaku proses pelatihan model; serta **metode evaluasi**, yang digunakan untuk mengukur kualitas ringkasan secara objektif. Dengan perancangan skenario yang sistematis, hasil pengujian diharapkan dapat memberikan gambaran yang jelas mengenai performa model serta validitas pendekatan yang digunakan dalam penelitian ini.

### 3.8.1 Lingkungan Pengujian

Pengujian model dilakukan pada perangkat *Apple Mac* dengan *chip Apple Silicon M4*, yang dilengkapi CPU terintegrasi berperforma tinggi, RAM 24 GB, dan sistem operasi *macOS*. *Chip M4* memiliki arsitektur komputasi berbasis ARM dengan akselerasi untuk operasi matriks, sehingga tetap mampu menjalankan proses pelatihan model berbasis RNN meskipun tanpa GPU eksternal. Seluruh proses pelatihan dilakukan secara lokal menggunakan kemampuan CPU dan Neural Engine yang tersedia pada perangkat.

Lingkungan pemrograman menggunakan *Python 3*, dengan framework utama *PyTorch* untuk membangun dan melatih arsitektur encoder-decoder berbasis BiGRU dan LSTM. Untuk tahap pra-pemrosesan teks Bahasa Indonesia, digunakan library **Sastrawi** untuk stemming, serta library pendukung lain seperti NumPy dan scikit-learn.

### 3.8.2 Hyperparameter Training

Pelatihan model dilakukan dengan menggunakan serangkaian hyperparameter yang lazim diterapkan pada arsitektur RNN untuk tugas peringkasan teks. Jumlah epoch ditentukan berdasarkan pemantauan nilai loss pada data validasi sehingga model berhenti sebelum mengalami overfitting. Sementara itu, batch size disesuaikan dengan kapasitas perangkat keras yang digunakan—dalam penelitian ini berkisar pada nilai moderat (16–64) untuk menjaga keseimbangan antara stabilitas pembaruan bobot dan efisiensi komputasi. Nilai learning rate ditetapkan secara konservatif dengan pendekatan warm-up kecil, biasanya pada rentang  $1e-4$  hingga  $5e-4$ , guna memastikan proses pelatihan berlangsung stabil sejak fase awal.

Selain itu, beberapa mekanisme regulasi diterapkan untuk menjaga stabilitas pelatihan, terutama karena arsitektur RNN rentan terhadap masalah exploding gradient. Teknik seperti dropout digunakan untuk mengurangi overfitting, sedangkan teacher forcing ratio disesuaikan agar model mampu belajar hubungan sekuens secara efektif tanpa terlalu bergantung pada data pelatihan. Gradient clipping juga diterapkan untuk mencegah pembaruan parameter yang terlalu ekstrem, sehingga pelatihan dapat berlangsung lebih konsisten hingga mencapai konvergensi yang diharapkan. Jika diperlukan, saya dapat menambahkan tabel hyperparameter resminya.



### 3.8.3 Metode Evaluasi

Evaluasi model dilakukan menggunakan metrik **ROUGE**, yang menjadi standar dalam penilaian otomatis kualitas ringkasan. ROUGE-1 mengukur kecocokan *unigram* antara ringkasan prediksi (*pred*) dan ringkasan referensi (*ref*). Di sini, *pred* adalah ringkasan yang dihasilkan oleh model, sementara *ref* adalah ringkasan acuan yang disediakan dalam dataset. Metrik ini menilai apakah model mampu menangkap kata-kata penting dari ringkasan referensi. Rumus ROUGE-1 (berbasis recall) adalah:

$$\text{ROUGE-1} = \frac{\sum_{w \in \text{ref}} \min(\text{count}(w_{\text{pred}}), \text{count}(w_{\text{ref}}))}{\sum_{w \in \text{ref}} \text{count}(w_{\text{ref}})} \quad (3.5)$$

ROUGE-2 mengevaluasi kecocokan *bigram*, sehingga lebih sensitif terhadap alur frasa dan transisi antar kata. Metrik ini menangkap kohesi lokal yang tidak ditangkap oleh *unigram*. Rumus umum ROUGE-2 adalah:

$$\text{ROUGE-2} = \frac{\sum_{b \in \text{ref}} \min(\text{count}(b_{\text{pred}}), \text{count}(b_{\text{ref}}))}{\sum_{b \in \text{ref}} \text{count}(b_{\text{ref}})} \quad (3.6)$$

Sementara itu, ROUGE-L dihitung dengan memanfaatkan **Longest Common Subsequence (LCS)** untuk menilai kesamaan struktur kalimat secara lebih global, sehingga sering digunakan untuk mengukur kelancaran dan kelogisan hasil ringkasan. ROUGE-L *recall* dirumuskan sebagai:

$$\text{ROUGE-L} = \frac{\text{LCS}(\text{pred}, \text{ref})}{|\text{ref}|} \quad (3.7)$$

Ketiga metrik ini memberikan gambaran komprehensif mengenai performa model dalam mempertahankan informasi utama, menjaga koherensi, dan menghasilkan ringkasan yang tetap relevan secara semantik maupun struktural.

Penggunaan kombinasi ROUGE-1, ROUGE-2, dan ROUGE-L memungkinkan analisis menyeluruh terhadap kualitas ringkasan dari aspek leksikal, frasal, hingga kesesuaian struktur secara keseluruhan.


## BAB IV

### MODEL RINGKASAN EKSTRAKTIF

Bab ini merupakan realisasi dari rangkaian tahapan yang telah dirumuskan pada metodologi penelitian, khususnya pada fase pertama yaitu peringkasan teks ekstraktif berbasis hybrid. Tujuan dari bab ini adalah menjelaskan bagaimana model diimplementasikan dalam lingkungan nyata, bagaimana prosedur uji coba dilakukan, serta bagaimana hasilnya dianalisis baik secara kuantitatif maupun kualitatif. Implementasi dilakukan dengan mempertimbangkan dua aspek utama: kualitas representasi teks dan efektivitas pemilihan kalimat.

#### 4.1 Implementasi dan Pemilihan Model (Model Implementation)

##### 4.1.1 Distribusi Jumlah Kalimat Perartikel

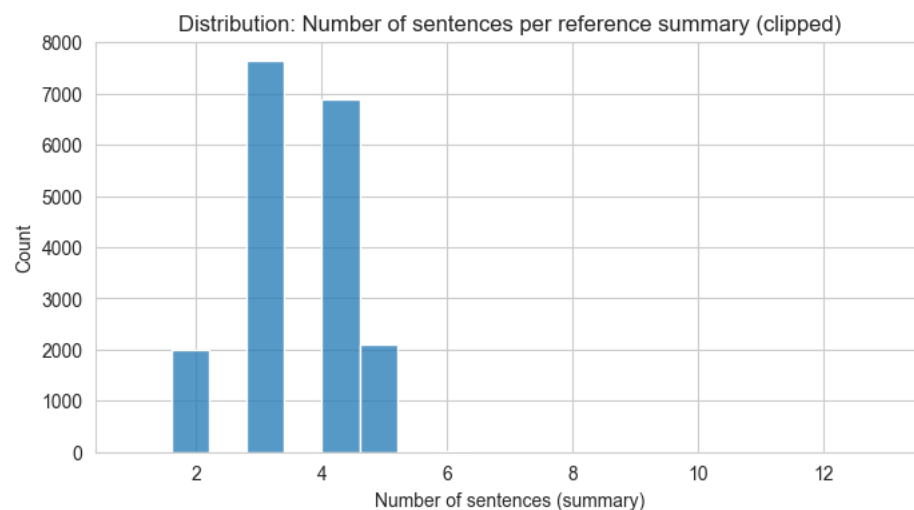


Gambar 4.1 Distribusi jumlah kalimat setiap artikel

Pada gambar 4.1 menjelaskan distribusi jumlah kalimat pada artikel menunjukkan bahwa sebagian besar artikel memiliki panjang antara 10 hingga 25 kalimat, dengan konsentrasi tertinggi pada rentang 15–20 kalimat. Hal ini

mengindikasikan bahwa teks berita dalam dataset cenderung memiliki struktur menengah, tidak terlalu pendek namun juga tidak terlalu panjang. Meskipun demikian, terdapat beberapa artikel dengan panjang ekstrem yang mencapai lebih dari 70 kalimat. Nilai-nilai ekstrem tersebut relatif jarang, sehingga dilakukan proses clipping untuk menjaga keterbacaan visual ketika menampilkan grafik distribusi.

#### 4.1.2 Distribusi Jumlah Kalimat pada Ringkasan Asli



Gambar 4.2 Distribusi Jumlah Kalimat pada Ringkasan Asli

Distribusi jumlah kalimat pada ringkasan referensi menunjukkan pola yang jauh lebih singkat. Mayoritas ringkasan terdiri dari 3 hingga 4 kalimat, dan sangat jarang ditemukan ringkasan yang melebihi 5 atau 6 kalimat. Pola ini sesuai dengan karakter umum ringkasan berita yang padat dan berfokus pada inti informasi. Dengan struktur ringkasan yang konsisten pendek, model peringkasan—baik ekstraktif maupun abstraktif—perlu diarahkan untuk menghasilkan output yang ringkas dan informatif. Pola distribusi ini juga memberikan dasar kuat untuk membatasi panjang ringkasan otomatis agar sesuai dengan karakteristik data,

sekaligus mendukung strategi pemilihan kalimat berbasis relevansi semantik pada tahap ekstraktif.

#### 4.1.3 Realisasi Pra-Pemrosesan Data (Data Preparation)

Tahap *preprocessing* merupakan proses fundamental untuk memastikan bahwa model tidak bekerja dengan data yang kotor atau ambigu. Jika unsur-unsur tersebut tidak dibersihkan, representasi TF-IDF dan *embedding* SBERT dapat menjadi bias atau tidak stabil, sehingga menurunkan akurasi perhitungan *similarity*.

Proses *cleaning* dilakukan secara bertahap. Pertama, seluruh teks dikonversi menjadi huruf kecil untuk menghindari duplikasi kata. Setelah itu, karakter non-alfabet dihapus termasuk tanda baca dan spasi berlebih. Selanjutnya, teks dipisahkan menjadi token-token individu melalui proses tokenisasi.

Hasil dari keseluruhan proses ini ditampilkan dalam tabel berikut sebagai bukti bahwa data telah melalui transformasi signifikan dari bentuk mentah ke bentuk siap-olah.

##### a. *Case Folding*

Tahap ini akan mengubah seluruh teks artikel menjadi huruf kecil.

Tabel 4. 1 Hasil *case folding*

Artikel
Padang, Sumbar – – Pemerintah Provinsi Sumatra Barat melalui Gubernur Mahyeldi Ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah Pesisir Selatan serta Kabupaten Agam. "Status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar Mahyeldi usai meninjau lokasi jembatan putus di kawasan Silaut, Selasa (16/3). Langkah ini diambil pemerintah daerah karena tingginya intensitas curah hujan yang mengakibatkan ribuan rumah terendam serta memutus akses jalan lintas barat Sumatra yang menghubungkan Padang dengan Bengkulu ....
Hasil

padang, sumbar – – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah pesisir selatan serta kabupaten agam. "status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar mahyeldi usai meninjau lokasi jembatan putus di kawasan silaut, Selasa (16/3). langkah ini diambil pemerintah daerah karena tingginya intensitas curah hujan yang mengakibatkan ribuan rumah terendam serta memutus akses jalan lintas barat sumatra yang menghubungkan padang dengan Bengkulu ....

## b. Sentence Tokenization

Pada tahap ini memecah teks artikel sesuai dengan kalimat didalamnya.

Tabel 4. 2 Hasil *Sentence Tokenization*

Artikel	
padang, sumbar – – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah pesisir selatan serta kabupaten agam. "status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar mahyeldi usai meninjau lokasi jembatan putus di kawasan silaut, Selasa (16/3). langkah ini diambil pemerintah daerah karena tingginya intensitas curah hujan yang mengakibatkan ribuan rumah terendam serta memutus akses jalan lintas barat sumatra yang menghubungkan padang dengan Bengkulu ....	
Hasil	
1	padang, sumbar – – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah pesisir selatan serta kabupaten agam.
2	"status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar mahyeldi usai meninjau lokasi jembatan putus di kawasan silaut, Selasa (16/3).
3	langkah ini diambil pemerintah daerah karena tingginya intensitas curah hujan yang mengakibatkan ribuan rumah terendam serta memutus akses jalan lintas barat sumatra yang menghubungkan padang dengan Bengkulu.
4	saat awal dinamika cuaca ekstrem melanda pekan lalu, tim bpbd bersama relawan kemanusiaan menjadi pihak pertama yang melakukan penyisiran dan mendirikan posko pengungsian darurat.

5	kepala pelaksana tugas penanggulangan bencana itu sempat menyebutkan bahwa tantangan utama di lapangan adalah medan yang tertimbun material lumpur tebal setinggi dua meter, sehingga alat berat dari dinas pekerjaan umum harus dikerahkan secara intensif.
6	pihak pemprov juga sempat berkoordinasi dengan pemerintah pusat guna meminta tambahan anggaran dana siap pakai untuk perbaikan infrastruktur vital yang rusak akibat terjangan air bah.
7	namun, proses distribusi bantuan sempat terkendala cuaca buruk yang kembali terjadi sehingga jalur udara sulit diakses helikopter pengangkut medis.
8	gubernur kini belum bisa merinci secara pasti total kerugian materiil karena masih fokus pada keselamatan jiwa penduduk di zona merah.
9	"rencananya besok saya ke jakarta dulu untuk melakukan rapat koordinasi dengan kepala bnpb kemudian hari jumat saya kembali ke lokasi pengungsian untuk memastikan ketersediaan pangan bagi anak-anak dan lansia," tuturnya.
10	ribuan warga telah resmi diungsikan ke aula kantor bupati dan masjid-masjid terdekat guna menghindari potensi longsor susulan dalam kondisi tanah yang masih labil malam ini.
11	penanganan darurat tersebut dipimpin langsung oleh komandan satgas penanggulangan bencana daerah setempat.

### c. Word Tokenization

Pada Tahap ini adalah memecah setiap kata dari artikel.

Tabel 4. 3 Hasil dari *word tokenization*

Kalimat
padang, sumbar – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah pesisir selatan serta kabupaten agam.
Token
["padang,", "sumbar", "--", "pemerintah", "provinsi", "sumatra", "barat", "melalui", "gubernur", "mahyeldi", "ansharullah", "menetapkan", "status", "tanggap", "darurat", "bencana", "menyusul", "banjir", "bandang", "dan", "longsor", "yang", "melanda", "wilayah", "pesisir", "selatan", "serta", "kabupaten", "agam."]

Tahap pra proses ini memastikan bahwa seluruh data input memiliki format standar yang konsisten, sehingga proses selanjutnya dapat berjalan lebih akurat dan efisien.

## 4.2 Realisasi Ekstraksi Fitur TF-IDF

Hasil yang ditampilkan merupakan keluaran dari proses ekstraksi fitur TF-IDF yang diterapkan pada salah satu artikel dalam dataset penelitian. Pada tahap ini, setiap kalimat dalam artikel diubah ke dalam representasi vektor berdasarkan bobot TF-IDF sehingga terlihat distribusi nilai penting (relevance weight) dari kata-kata yang menyusun kalimat tersebut. Proses ini menghasilkan matriks fitur yang menunjukkan kontribusi setiap kata dalam membentuk makna kalimat. Dari hasil ekstraksi ini dapat diamati bahwa kalimat-kalimat yang mengandung kata bernilai IDF tinggi, karena jarang muncul tetapi sangat informatif, memperoleh bobot yang lebih besar. Representasi inilah yang kemudian digunakan dalam proses perhitungan cosine similarity untuk memilih kalimat paling relevan sebagai ringkasan ekstraktif. Dengan demikian, visualisasi tersebut menggambarkan secara langsung bagaimana fitur TF-IDF bekerja pada artikel nyata dalam dataset dan berperan sebagai dasar sebelum model memasuki tahap peringkasan abstraktif.

Berikut hasil penghitungan menggunakan TF-IDF :

Tabel 4. 4 Penilain menggunakan TF-IDF

No	Kalimat	Nilai TF-IDF
1	padang, sumbar – – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ...	[0.1551, 0.1716, 0.2228, 0.2605, 0.1416...]
2	status ini berlaku selama dua minggu ke depan untuk mempercepat ...	[0.2733, 0.2366, 0.1902, 0.2733, 0.2366...]
3	langkah ini diambil pemerintah daerah karena tingginya intensitas ....	[0.2427, 0.3487, 0.2216, 0.3018, 0.2038...]
..	....	....
11	penanganan darurat tersebut dipimpin langsung oleh komandan satgas ....	[0.3773, 0.2905, 0.3773, 0.2205, 0.3773...]



### 4.3 Implementasi SBERT (Semantic Embedding)

SBERT digunakan untuk menghasilkan embedding kalimat yang dapat mengukur kedekatan makna melalui cosine similarity. Berbeda dengan TF-IDF, pendekatan ini tidak membutuhkan frekuensi kata; SBERT langsung memahami konteks kalimat melalui representasi 384 dimensi.

Tabel 4. 5 Hasil SBERT

No	Kalimat	Nilai S-BERT
1	padang, sumbar – – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ...	[-0.1196, 0.1740, 0.2464, 0.0950, 0.0109, -0.0592, 0.0594, 0.0146, 0.0757, 0.2468...]
2	status ini berlaku selama dua minggu ke depan untuk mempercepat ...	[-0.0213, 0.1008, 0.0496, 0.0654, -0.0269, 0.0238, 0.0617, -0.0513, 0.0957, 0.0686...]
3	langkah ini diambil pemerintah daerah karena tingginya intensitas ....	[-0.0809, 0.2795, -0.0919, -0.1073, 0.1271, 0.2011, 0.1051, -0.0206, 0.0183, 0.0413...]
...	....	...
11	penanganan darurat tersebut dipimpin langsung oleh komandan satgas ....	[-0.1228, 0.3197, 0.1464, -0.0051, 0.1300, -0.0137, 0.0946, 0.1199, 0.0156, 0.2395...]

Embedding ini memungkinkan model membaca kalimat yang relevan meskipun tidak memiliki kesamaan kata secara langsung.

### 4.4 Cosine Similarity

Pada bagian ini, kita akan melakukan tahap kritis dalam *Extractive Text Summarization*, yaitu penilaian skor (*scoring*) untuk setiap kalimat dalam artikel. Tujuan utama dari penilaian ini adalah mengidentifikasi kalimat mana yang memiliki kemiripan semantik atau konten yang paling tinggi dengan tema sentral artikel, yang diwakili oleh judul artikel. Kalimat dengan skor tertinggi akan dipilih sebagai ringkasan. Metode yang digunakan untuk mengukur kemiripan antara dua vektor (kalimat dan judul) adalah *Cosine Similarity*.

#### 4.4.1 CS TF-IDF

Pada tabel 4.6 dibawah ini memperlihatkan hasil penilaian kemiripan setiap kalimat dengan judul artikel menggunakan TF-IDF

Tabel 4. 6 Hasil CS TF-IDF

No	Kalimat	CS TF-IDF
1	padang, sumbar – – pemerintah provinsi sumatra...	0.4137
2	"status ini berlaku selama dua minggu ke depan...	0.0622
3	langkah ini diambil pemerintah daerah karena t...	0.0000
4	saat awal dinamika cuaca ekstrem melanda pekan...	0.0614
5	kepala pelaksana tugas penanggulangan bencana ...	0.0300
6	pihak pemprov juga sempat berkoordinasi dengan...	0.1137
7	namun, proses distribusi bantuan sempat terken...	0.0000
8	gubernur kini belum bisa merinci secara pasti ...	0.0000
9	"rencananya besok saya ke jakarta dulu untuk m...	0.0198
10	ribuan warga telah resmi diungsikan ke aula ka...	0.0649
11	penanganan darurat tersebut dipimpin langsung ...	0.1028

#### 4.4.2 CS SBERT

Pada tabel 4.7 dibawah ini memperlihatkan hasil penilaian kemiripan setiap kalimat dengan judul artikel menggunakan SBERT

Tabel 4. 7 Hasil CS SBERT

No	Kalimat	CS S-BERT
1	padang, sumbar – – pemerintah provinsi sumatra...	0.6357
2	"status ini berlaku selama dua minggu ke depan...	0.5162
3	langkah ini diambil pemerintah daerah karena t...	0.3795
4	saat awal dinamika cuaca ekstrem melanda pekan...	0.5556
5	kepala pelaksana tugas penanggulangan bencana ...	0.5025
6	pihak pemprov juga sempat berkoordinasi dengan...	0.3940
7	namun, proses distribusi bantuan sempat terken...	0.3547
8	gubernur kini belum bisa merinci secara pasti ...	0.3719
9	"rencananya besok saya ke jakarta dulu untuk m...	0.0664
10	ribuan warga telah resmi diungsikan ke aula ka...	0.1916
11	penanganan darurat tersebut dipimpin langsung ...	0.5960

#### 4.5 Penilaian

Mengingat kelebihan dan kekurangan dari masing-masing metode feature extraction (TF-IDF yang unggul dalam akurasi leksikal, dan S-BERT yang unggul dalam akurasi semantik kontekstual), langkah selanjutnya adalah menggabungkan

kedua nilai Cosine Similarity (CS) untuk mendapatkan skor kalimat yang lebih komprehensif dan seimbang, perhatikan tabel 4.8 dibawah ini.

Tabel 4. 8 Hasil penggabungan

No	Kalimat	CS_TF-IDF	CS_S-BERT	S_Final
1	padang, sumbar – – pemerintah provinsi sumatra...	0.4137	0.6357	0.5247
2	"status ini berlaku selama dua minggu ke depan...	0.0622	0.5162	0.2892
3	langkah ini diambil pemerintah daerah karena t...	0.0000	0.3795	0.1897
4	saat awal dinamika cuaca ekstrem melanda pekan...	0.0614	0.5556	0.3085
5	kepala pelaksana tugas penanggulangan bencana ...	0.0300	0.5025	0.2663
6	pihak pemprov juga sempat berkoordinasi dengan...	0.1137	0.3940	0.2538
7	namun, proses distribusi bantuan sempat terken...	0.0000	0.3547	0.1774
8	gubernur kini belum bisa merinci secara pasti ...	0.0000	0.3719	0.1859
9	"rencananya besok saya ke jakarta dulu untuk m...	0.0198	0.0664	0.0431
10	ribuan warga telah resmi diungsikan ke aula ka...	0.0649	0.1916	0.1282
11	penanganan darurat tersebut dipimpin langsung ...	0.1028	0.5960	0.3494

Tabel di atas menunjukkan bahwa empat kalimat dengan skor S\_Final tertinggi adalah kalimat 1, 2, 4, dan 5, yang secara kumulatif membentuk kombinasi dengan total skor tertinggi di antara semua kalimat.

#### 4.6 Hasil Peringkasan Ekstraktif

Tabel 4.9 adalah contoh transformasi artikel sebelum dan sesudah menjadi peringkasan abstraktif

Tabel 4. 9 Contoh Hasil

Artikel
Padang, Sumbar – – Pemerintah Provinsi Sumatra Barat melalui Gubernur Mahyeldi Ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah Pesisir Selatan serta Kabupaten Agam. "Status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar

Mahyeldi usai meninjau lokasi jembatan putus di kawasan Silaut, Selasa (16/3). Langkah ini diambil pemerintah daerah karena tingginya intensitas curah hujan yang mengakibatkan ribuan rumah terendam serta memutus akses jalan lintas barat Sumatra yang menghubungkan Padang dengan Bengkulu. Saat awal dinamika cuaca ekstrem melanda pekan lalu, tim BPBD bersama relawan kemanusiaan menjadi pihak pertama yang melakukan penyisiran dan mendirikan posko pengungsian darurat. Kepala pelaksana tugas penanggulangan bencana itu sempat menyebutkan bahwa tantangan utama di lapangan adalah medan yang tertimbun material lumpur tebal setinggi dua meter, sehingga alat berat dari dinas pekerjaan umum harus dikerahkan secara intensif. Pihak pemprov juga sempat berkoordinasi dengan pemerintah pusat guna meminta tambahan anggaran dana siap pakai untuk perbaikan infrastruktur vital yang rusak akibat terjangkit air bah. Namun, proses distribusi bantuan sempat terkendala cuaca buruk yang kembali terjadi sehingga jalur udara sulit diakses helikopter pengangkut medis. Gubernur kini belum bisa merinci secara pasti total kerugian materiil karena masih fokus pada keselamatan jiwa penduduk di zona merah. "Rencananya besok saya ke Jakarta dulu untuk melakukan rapat koordinasi dengan Kepala BNPB kemudian hari Jumat saya kembali ke lokasi pengungsian untuk memastikan ketersediaan pangan bagi anak-anak dan lansia," tuturnya.

#### Ringkasan

(1)padang, sumbar – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah pesisir selatan serta kabupaten agam. (2)"status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar mahyeldi usai meninjau lokasi jembatan putus di kawasan silaut, selasa (16/3). (4)saat awal dinamika cuaca ekstrem melanda pekan lalu, tim bpbd bersama relawan kemanusiaan menjadi pihak pertama yang melakukan penyisiran dan mendirikan posko pengungsian darurat. (5)kepala pelaksana tugas penanggulangan bencana itu sempat menyebutkan bahwa tantangan utama di lapangan adalah medan yang tertimbun material lumpur tebal setinggi dua meter, sehingga alat berat dari dinas pekerjaan umum harus dikerahkan secara intensif.

#### Ringkasan Asli

Gubernur Sumatra Barat menetapkan status tanggap darurat selama dua minggu untuk mempercepat evakuasi dan penyaluran bantuan bagi korban banjir bandang serta tanah longsor di Pesisir Selatan dan Agam. Bencana ini menyebabkan ribuan rumah terendam, jembatan putus, dan akses jalan lintas barat Sumatra lumpuh total akibat timbunan material lumpur yang sangat tebal. Meskipun distribusi bantuan sempat terkendala cuaca buruk, pemerintah daerah terus berkoordinasi dengan BNPB untuk memastikan kebutuhan logistik dan keselamatan ribuan warga di pengungsian terpenuhi.

#### 4.7 Analisis Hasil

Untuk mengevaluasi kualitas ringkasan ekstraktif yang dihasilkan dari 1800+ dokumen berita berbahasa Indonesia, penelitian ini menggunakan metrik ROUGE (Recall-Oriented Understudy for Gisting Evaluation). ROUGE merupakan metrik yang paling banyak digunakan untuk menilai kualitas ringkasan, terutama pada penelitian-penelitian summarization berbasis machine learning dan deep learning.

Pada konteks ringkasan ekstraktif, nilai ROUGE yang tinggi menunjukkan bahwa kalimat-kalimat yang dipilih oleh sistem memiliki tingkat kesesuaian yang kuat dengan ringkasan referensi (gold summary) yang ditulis manusia. Oleh karena itu, analisis statistik seperti mean, median, standar deviasi, nilai minimum, dan maksimum sangat penting untuk memahami performa sistem secara global maupun distribusinya di seluruh dataset.

Tabel 4. 10 Statistik Hasil ROUGE *score*

	<b>Metric</b>	<b>Mean</b>	<b>Median</b>	<b>Std Dev</b>	<b>Min</b>	<b>Max</b>
0	ROUGE-1	0.5103	0.5072	0.1593	0.0159	1.0
1	ROUGE-2	0.4058	0.4000	0.1977	0.0000	1.0
2	ROUGE-L	0.4577	0.4522	0.1813	0.0159	1.0

Hasil evaluasi menunjukkan bahwa sistem ekstraktif yang dikembangkan memiliki performa moderat berdasarkan metrik ROUGE. Nilai mean ROUGE-1 sebesar 0.5103 mengindikasikan bahwa sekitar separuh dari kata-kata dalam ringkasan yang dihasilkan tumpang tindih dengan ringkasan referensi. Nilai median ROUGE-1 sebesar 0.5072, yang hampir setara dengan rata-ratanya, menunjukkan

bahwa distribusi performa cenderung simetris dan mayoritas ringkasan berada pada kisaran kualitas sedang.

Pada metrik bigram (ROUGE-2), sistem mencatat mean 0.4058 dan median 0.4000, yang mencerminkan kemampuan sistem dalam mempertahankan urutan pasangan kata (*word sequence*) yang relevan dengan cukup memadai. Namun, nilai ini lebih rendah dibandingkan ROUGE-1, sebagaimana lazim terjadi karena ROUGE-2 lebih ketat dalam menilai kesesuaian struktur kalimat. Standar deviasi yang relatif tinggi (0.1977) menunjukkan adanya variasi signifikan dalam kualitas ringkasan, kemungkinan besar dipengaruhi oleh keragaman topik, panjang dokumen, atau kompleksitas struktur kalimat dalam dataset berita berbahasa Indonesia.

Untuk ROUGE-L, yang mengukur longest common subsequence sebagai indikator kesamaan struktur kalimat, sistem mencapai mean 0.4577 dan median 0.4522. Nilai ini menunjukkan bahwa sistem mampu menangkap urutan kata yang koheren dan relevan, meskipun tidak sekuat dalam menangkap kesamaan kata individual (ROUGE-1).

Nilai minimum yang mendekati nol (misalnya 0.0159 untuk ROUGE-1 dan ROUGE-L, serta 0.0000 untuk ROUGE-2) mengindikasikan adanya kasus-kasus ekstrem di mana ringkasan yang dihasilkan hampir tidak memiliki kesamaan dengan referensi. Hal ini dapat disebabkan oleh: (1) dokumen yang sangat pendek atau tidak informatif, (2) Ringkasan referensi yang bersifat parafrase abstraktif (sehingga tidak tumpang tindih secara langsung dengan kalimat asli), (3) atau kegagalan sistem dalam memilih kalimat yang representatif.

Di sisi lain, nilai maksimum 1.0 pada ketiga metrik menunjukkan bahwa terdapat sejumlah contoh di mana ringkasan yang dihasilkan identik atau hampir sepenuhnya tumpang tindih dengan ringkasan referensi, mencerminkan performa optimal pada kasus-kasus tertentu.

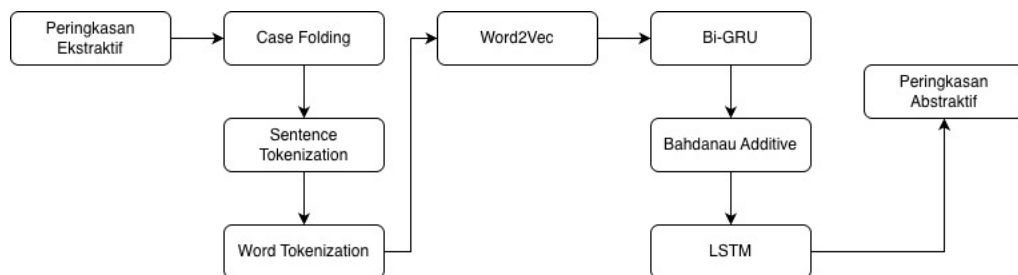
Secara keseluruhan, nilai ROUGE yang diperoleh berada dalam kisaran yang dapat diterima untuk tugas ringkasan ekstraktif, terutama mengingat tantangan dari keragaman gaya penulisan dalam teks berita berbahasa Indonesia. Temuan ini menunjukkan bahwa sistem mampu menghasilkan ringkasan yang cukup relevan dan representatif, meski masih terdapat ruang untuk peningkatan, terutama dalam penanganan dokumen dengan struktur kompleks atau referensi yang bersifat abstraktif.

## BAB V

### PERINGKASAN ABSTRAKTIF DENGAN SOURCE PERINGKASAN EKSTRAKTIF

#### 5.1 Desain Sistem

Pada tahap ini, dilakukan realisasi dari pemilihan model yang telah ditentukan pada tahap desain, khususnya dalam membangun arsitektur *deep learning hibrida* yaitu menggunakan peringkasan ekstraktif untuk tugas peringkasan abstraktif.



Gambar 5.1 Desain sistem dengan source peringkasan ekstraktif

Gambar 5.1 menerangkan bahwa source yang digunakan adalah hasil peringkasan ekstraktif pada bab 4. Pra pemrosesan yang dilakukan adalah *case folding* yaitu mengubah kalimat menjadi huruf kecil, *Sentence tokenization* untuk memecah kalimat. *Word Tokenization* untuk memecah setiap kata. *Word2vec* digunakan untuk mengubah setiap kata menjadi *vector*. Selanjutnya adalah *encoder* menggunakan Bi-Gru, *Bahdanau additive* sebagai *brige*, dan *encoder* menggunakan LSTM.

#### 5.2 Word2Vec Embedding

Sebelum melakukan ekstraksi fitur menggunakan Word2Vec, teks peringkasan abstraktif perlu melalui preprocessing terlebih dahulu.



### 5.2.1 Hasil *Preprocessing*

Pada proses ini sama dengan apa yang dibahas pada bab 4, dimana teks peringkasan ekstraktif diproses. Dimulai dengan mengubahnya menjadi huruf kecil memecah kalimat dan memecah kata. Teks yang sudah diproses ini kemudian diubah menjadi vector menggunakan *word2vec embedding*.

### 5.2.2 Representasi Numeric

Tabel 5.1 Tabel ini menunjukkan proses awal transformasi teks berita menjadi representasi numerik yang dapat diproses oleh model deep learning.

Tabel 5.1 Hasil Vektorisasi

Kalimat	Token	Vektor
Padang, Sumbar -- pemerintah provinsi sumatra barat melalui gubernur mahyeldi ansharullah menetapkan status tanggap darurat bencana...	['padang', 'sumbar', 'pemerintah', 'provinsi', 'sumatra', 'barat', 'melalui', 'gubernur', 'mahyeldi', 'ansharullah', 'menetapkan', 'status', 'tanggap', 'darurat', 'bencana']...	[2, 8, 15, 7, 69, 139, 118, 410, 2625, 4616, 2137, 7531, 14113, 23, 69]...
"Status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar Mahyeldi...	['status', 'ini', 'berlaku', 'selama', 'dua', 'minggu', 'ke', 'depan', 'untuk', 'mempercepat', 'proses', 'evakuasi', 'dan', 'penyaluran', 'bantuan', 'logistik']...	[2, 35, 34, 3306, 7531, 14113, 140, 2625, 228, 1686, 4607, 5755, 23, 69, 171]..
Langkah ini diambil pemerintah daerah karena tingginya intensitas curah hujan yang mengakibatkan ribuan rumah terendam serta memutus akses jalan...	['langkah', 'ini', 'diambil', 'pemerintah', 'daerah', 'karena', 'tingginya', 'intensitas', 'curah', 'hujan', 'yang', 'mengakibatkan', 'ribuan', 'rumah', 'terendam']...	[2, 7531, 24, 13, 1033, 23, 220, 164, 1294, 171, 698, 4131, 32, 144, 2932]...
Kepala pelaksana tugas penanggulangan bencana itu sempat menyebutkan bahwa tantangan utama di lapangan adalah medan yang tertimbun material lumpur...	['kepala', 'pelaksana', 'tugas', 'penanggulangan', 'bencana', 'itu', 'sempat', 'menyebutkan', 'bahwa', 'tantangan', 'utama', 'di', 'lapangan', 'adalah', 'medan']...	[2, 698, 4131, 32, 144, 2932, 23, 69, 171, 1111, 240, 424, 478, 14, 507]...

Setiap kalimat dipecah menjadi token (kata) melalui tokenisasi, lalu setiap token dipetakan ke ID unik berdasarkan vocabulary yang telah dibangun sebelumnya. Misalnya, kata "jakarta" dipetakan ke ID 2, "cnn" ke 8, dan seterusnya. Ini adalah langkah wajib karena model seperti Bi-GRU tidak dapat memproses teks langsung, tetapi hanya menerima urutan angka (integer sequences).

### 5.2.3 Vektorisasi

Tabel 5.2 menunjukkan hasil vektorisasi akhir dari teks input setelah melewati lapisan embedding, yang merupakan langkah krusial sebelum data dimasukkan ke encoder Bi-GRU. Setiap token (termasuk token khusus seperti <s>, </s>, dan <pad>) diubah dari ID numerik menjadi vektor dense berdimensi 256 melalui learned embedding layer — atau, jika menggunakan embedding pralatih (pre-trained), melalui vektor Word2Vec/FastText yang telah di-load.


Tabel 5. 2 Hasil Vektorisasi

Token	Token ID	Vektor Embedding (256-dimensi, contoh 5 nilai pertama)
<s>	2	[0.00, 0.00, 0.00, 0.00, 0.00, ...]
padang	8	[-0.42, 0.18, -1.05, 0.73, -0.29, ...]
sumbar	15	[0.61, -0.33, 0.92, -0.11, 0.44, ...]
pemerintah	7	[-0.19, 0.55, -0.67, 0.88, 0.02, ...]
provinsi	23	[0.34, -0.71, 0.22, -0.45, 0.63, ...]
sumatra	69	[-0.88, 0.12, 0.39, -0.07, -0.51, ...]
...	...	...
</s>	3	[0.00, 0.00, 0.00, 0.00, 0.00, ...]
<pad>	0	[0.00, 0.00, 0.00, 0.00, 0.00, ...]

Vektor ini menangkap makna semantik dan relasi kontekstual antar kata, sehingga memungkinkan Bi-GRU memahami struktur dan isi kalimat secara lebih mendalam. Misalnya, vektor untuk “ketua” dan “dpr” kemungkinan berada dalam ruang vektor yang berdekatan karena sering muncul bersama dalam konteks politik.

Output akhir dari proses ini adalah tensor numerik berbentuk  $[1, N, 256]$  (untuk satu sampel), di mana  $N$  adalah panjang urutan maksimum setelah padding. Tensor inilah yang menjadi input langsung ke encoder Bi-GRU dalam arsitektur sequence-to-sequence untuk abstractive summarization.

### 5.3 Proses Training



Gambar 5.2 Training dengan input peringkasan ekstraktif

Gambar 5.2 menjelaskan proses pelatihan model dilakukan selama 20 epoch dengan penerapan teknik teacher forcing yang secara bertahap dikurangi dari rasio 1.0 (100%) pada epoch pertama hingga 0.05 (5%) pada epoch terakhir. Hal ini bertujuan untuk membantu model belajar secara stabil di awal pelatihan dengan mengandalkan ground truth sebagai input decoder, lalu secara progresif melatih model untuk mengandalkan outputnya sendiri guna menyerupai kondisi inferensi yang sesungguhnya. Selama pelatihan, training loss mengalami penurunan tajam dari 7.39 pada epoch pertama menjadi sekitar 1.77 pada epoch ke-10, menunjukkan bahwa model berhasil menangkap pola dasar dalam data. Namun, setelah epoch ke-15, training loss mulai mengalami kenaikan perlahan (mencapai 2.39 di epoch ke-

20), sementara validation loss terus menurun hingga mencapai 4.88 pada akhir pelatihan.

Pola ini mengindikasikan adanya gejala awal overfitting, di mana model mulai terlalu menyesuaikan diri pada data latih, meskipun kemampuan generalisasinya terhadap data validasi masih terjaga. Waktu pelatihan per epoch relatif stabil, sekitar 261–263 detik, menunjukkan komputasi yang efisien tanpa gangguan signifikan. Secara keseluruhan, model menunjukkan pembelajaran yang efektif pada 10–15 epoch pertama.

#### 5.4 Hasil Ringkasan

Dari proses diatas kita dapat menghasilkan ringkasan seperti yang ditunjukkan Tabel 5.3. Tabel tersebut memperlihatkan hasil dari peringkasan abstraktif dengan *source input* peringkasan ekstraktif

Tabel 5. 3 Hasil Peringkasan Abstractif

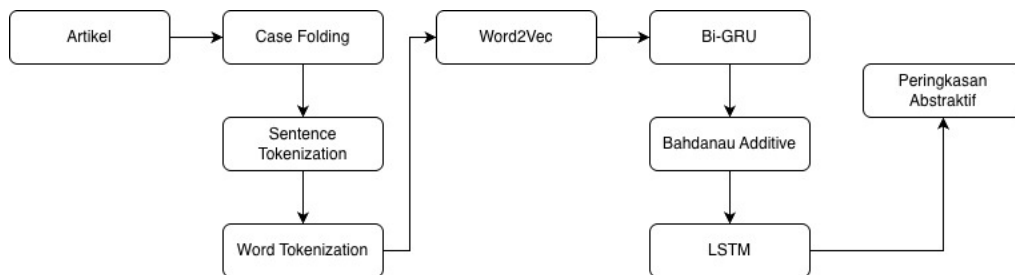
Peringkasan Ekstraktif
padang, sumbar – – pemerintah provinsi sumatra barat melalui gubernur mahyeldi ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah pesisir selatan serta kabupaten agam. (2)"status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar mahyeldi usai meninjau lokasi jembatan putus di kawasan silaut, selasa (16/3). (4)saat awal dinamika cuaca ekstrem melanda pekan lalu, tim bpbd bersama relawan kemanusiaan menjadi pihak pertama yang melakukan penyisiran dan mendirikan posko pengungsian darurat. (5)kepala pelaksana tugas penanggulangan bencana itu sempat menyebutkan bahwa tantangan ...
Ringkasan Abstraktif
padang pemerintah pemerintah provinsi barat barat melalui gubernur <unk> <unk> menetapkan status tanggap darurat bencana banjir dan longsor longsor wilayah kabupaten kabupaten kabupaten kabupaten kabupaten ini ini selama selama dua minggu ke depan depan dan dan bantuan logistik <unk> <unk> di di <unk> <unk> di di <unk> <unk> yang di
Ringkasan Asli
Gubernur Sumatra Barat menetapkan status tanggap darurat selama dua minggu untuk mempercepat evakuasi dan penyaluran bantuan bagi korban banjir bandang serta tanah longsor di Pesisir Selatan dan Agam. Bencana ini menyebabkan ribuan rumah terendam, jembatan putus, dan akses jalan lintas barat Sumatra lumpuh total akibat timbunan material lumpur yang sangat tebal. Meskipun distribusi bantuan sempat terkendala cuaca buruk, pemerintah daerah terus berkoordinasi dengan BNPB untuk memastikan kebutuhan logistik dan keselamatan ribuan warga di pengungsian terpenuhi.

## BAB VI

### PERINGKASAN ABSTRAKTIF DENGAN SOURCE ARTIKEL

#### 6.1 Desain Sistem

Pada tahap ini, adalah pengerjaan proses peringkasan abstraktif menggunakan source langsung dengan artikel.




Gambar 6.1 Desain sistem dengan source artikel

Gambar 6.1 menerangkan bahwa source yang digunakan adalah langsung menggunakan artikel secara keseluruhan. Pra pemrosesan yang dilakukan adalah *case folding* yaitu mengubah kalimat menjadi huruf kecil, *Sentence tokenization* untuk memecah kalimat. *Word Tokenization* untuk memecah setiap kata. *Word2vec* digunakan untuk mengubah setiap kata menjadi *vector*. Selanjutnya adalah *encoder* menggunakan Bi-Gru, *Bahdanau additive* sebagai *brige*, dan *encoder* menggunakan LSTM.

#### 6.2 Word2vec Embedding

Sebelum mengubah kata menjadi vektor menggunakan Word2Vec, teks artikel melalui preprocessing terlebih dahulu. Pada dasarnya tahap ini mirip seperti pada poin 5.2, yang membedakan adalah pada tahap ini inputan adalah artikel berita keseluruhan bukan peringkasan ekstraktif

### 6.3 Proses Training



Gambar 6.2 Proses training dengan input teks artikel keseluruhan

Gambar 6.2 menjelaskan pelatihan model pada eksperimen ini dilakukan selama 20 epoch dengan menggunakan seluruh teks artikel sebagai input, berbeda dari eksperimen sebelumnya yang hanya menggunakan kalimat-kalimat hasil ringkasan ekstraktif. Perubahan ini meningkatkan kompleksitas tugas karena model kini harus belajar menyaring, memahami, dan merangkum informasi dari teks panjang secara abstraktif, bukan hanya merekonstruksi kalimat yang sudah dipilih.

Dalam proses pelatihan, training loss menurun secara bertahap dari 7.39 di epoch pertama hingga mencapai 2.93 di epoch ke-20, namun laju penurunannya lebih lambat dibandingkan eksperimen sebelumnya, yang mencerminkan tantangan lebih besar dalam memproses konteks yang lebih luas. Sementara itu, validation loss berfluktuasi di kisaran 6.0–7.5, tanpa penurunan signifikan setelah epoch ke-10, menunjukkan bahwa model mengalami kesulitan untuk generalisasi terhadap data validasi, kemungkinan karena kompleksitas input yang lebih tinggi dan kurangnya kapasitas model atau teknik regularisasi yang cukup.

Penggunaan teacher forcing ratio yang berkurang secara bertahap dari 1.0 menjadi 0.05 tetap diterapkan, namun tidak cukup untuk mencegah stagnasi performa validasi. Waktu pelatihan per epoch relatif stabil di sekitar 500–525 detik, kecuali pada epoch ke-16 yang melonjak drastis hingga 2732 detik, kemungkinan akibat bottleneck memori, gangguan sistem, atau proses evaluasi tambahan. Secara keseluruhan, hasil ini menunjukkan bahwa meskipun model mampu belajar dari teks penuh, performa generalisasi masih perlu ditingkatkan, dan strategi seperti penambahan layer attention, penggunaan encoder yang lebih kuat (misalnya Transformer), atau penerapan teknik curriculum learning yang lebih halus mungkin diperlukan untuk mengatasi kompleksitas input yang lebih tinggi.

#### 6.4 Hasil Peringkasan

Dari proses diatas kita dapat menghasilkan ringkasan seperti yang ditunjukkan Tabel 6.1. Tabel tersebut memperlihatkan hasil dari abstraktif summarization dengan *source input* peringkasan ekstraktif

Tabel 6. 1 Contoh hasil peringkasan abstraktif

Artikel
Padang, Sumbar – Pemerintah Provinsi Sumatra Barat melalui Gubernur Mahyeldi Ansharullah menetapkan status tanggap darurat bencana menyusul banjir bandang dan longsor yang melanda wilayah Pesisir Selatan serta Kabupaten Agam. "Status ini berlaku selama dua minggu ke depan untuk mempercepat proses evakuasi dan penyaluran bantuan logistik bagi warga terdampak," ujar Mahyeldi usai meninjau lokasi jembatan putus di kawasan Silaut, Selasa (16/3). Langkah ini diambil pemerintah daerah karena tingginya intensitas curah hujan yang mengakibatkan ribuan rumah terendam serta memutus akses jalan lintas barat Sumatra yang menghubungkan Padang dengan Bengkulu. Saat awal dinamika cuaca ekstrem melanda pekan lalu, tim BPBD bersama relawan kemanusiaan menjadi pihak pertama yang melakukan penyisiran dan mendirikan posko pengungsian darurat. Kepala pelaksana tugas penanggulangan bencana itu sempat menyebutkan bahwa tantangan utama di lapangan adalah medan yang tertimbun material lumpur tebal setinggi dua meter, sehingga alat berat dari dinas pekerjaan umum harus dikerahkan secara intensif. Pihak pemprov juga sempat berkoordinasi dengan pemerintah pusat guna meminta tambahan anggaran dana siap pakai untuk perbaikan infrastruktur vital yang rusak akibat terjangan air bah. Namun, proses distribusi bantuan sempat terkendala cuaca buruk yang kembali terjadi sehingga jalur udara sulit diakses helikopter pengangkut medis. Gubernur kini belum bisa merinci secara pasti total kerugian materiil karena masih fokus pada keselamatan jiwa penduduk di zona merah. "Rencananya besok saya ke Jakarta dulu untuk melakukan rapat koordinasi dengan Kepala BNPB

kemudian hari Jumat saya kembali ke lokasi pengungsian untuk memastikan ketersediaan pangan bagi anak-anak dan lansia," tuturnya. Ribuan warga telah resmi diungsikan ke aula kantor bupati dan masjid-masjid terdekat guna menghindari potensi longsor susulan dalam kondisi tanah yang masih labil malam ini. Penanganan darurat tersebut dipimpin langsung oleh komandan satgas penanggulangan bencana daerah setempat.

#### **Ringkasan Abstraktif**

pemerintah provinsi kabupaten <unk> barat <unk> longsor melanda provinsi provinsi banten melalui gubernur <unk> <unk> <unk> status tanggap darurat bencana longsor dan longsor longsor longsor longsor longsor longsor longsor longsor longsor longsor longsor longsor longsor wilayah kabupaten yang longsor wilayah pesisir serta kabupaten <unk> kabupaten <unk> <unk> <unk> selama

#### **Ringkasan Asli**


Gubernur Sumatra Barat menetapkan status tanggap darurat selama dua minggu untuk mempercepat evakuasi dan penyaluran bantuan bagi korban banjir bandang serta tanah longsor di Pesisir Selatan dan Agam. Bencana ini menyebabkan ribuan rumah terendam, jembatan putus, dan akses jalan lintas barat Sumatra lumpuh total akibat timbunan material lumpur yang sangat tebal. Meskipun distribusi bantuan sempat terkendala cuaca buruk, pemerintah daerah terus berkoordinasi dengan BNPB untuk memastikan kebutuhan logistik dan keselamatan ribuan warga di pengungsian terpenuhi.



## BAB VII


### PEMBAHASAN

#### 7.1 Hasil Pelatihan (*Training Loss*)



Gambar 7.1 Training dengan input peringkasan ekstraktif

Gambar 7.1 menggambarkan dinamika pelatihan model abstractive summarization ketika input yang digunakan adalah ringkasan ekstraktif, yaitu, kalimat-kalimat yang telah dipilih secara otomatis dari teks asli sebagai representasi inti isi artikel. Dalam skenario ini, model encoder Bi-GRU menerima urutan kata yang lebih pendek dan sudah terfilter, sehingga tugasnya lebih fokus pada transformasi dan reformulasi kalimat daripada penyaringan informasi. Hasil pelatihan menunjukkan training loss yang turun sangat cepat dan stabil hingga epoch ke-10, kemudian mulai stagnan atau sedikit naik, indikasi bahwa model cepat belajar pola sederhana namun berpotensi overfit jika dilatih terlalu lama. Sementara itu, validation loss tetap menurun sepanjang pelatihan, menandakan bahwa model masih mampu generalisasi meskipun inputnya lebih “bersih” dan terbatas.




Gambar 7.2 Training dengan input teks artikel

Sebaliknya, Gambar 7.2 merepresentasikan pelatihan model dengan input teks artikel utuh, di mana encoder Bi-GRU harus memproses seluruh konten, sering kali panjang, berisi noise, dan membutuhkan pemahaman kontekstual yang lebih dalam. Dalam eksperimen ini, training loss menurun lebih lambat dan tidak mencapai level rendah seperti pada Gambar 7.1, bahkan cenderung naik setelah epoch ke-15. Hal ini mencerminkan tantangan besar yang dihadapi model: menyaring informasi penting, memahami hubungan antar kalimat, dan menghasilkan ringkasan yang koheren tanpa bantuan pra-pemilihan kalimat. Lebih menarik lagi, validation loss pada eksperimen ini justru lebih tinggi dan kurang stabil, menunjukkan bahwa model kesulitan untuk mempelajari representasi yang generalisasi dari data validasi, sebuah indikator bahwa kompleksitas input melebihi kapasitas model saat ini.

Dengan demikian, perbandingan antara Gambar 7.1 dan 7.2 bukan hanya sekadar evaluasi numerik, tetapi analisis mendalam tentang bagaimana representasi input memengaruhi efektivitas mekanisme attention dan kapasitas model dalam melakukan abstraksi makna. Hasil ini memberikan dasar kuat untuk pengembangan

model selanjutnya, misalnya dengan menambahkan layer attention hierarkis, memperpendek input melalui preprocessing ekstraktif, atau beralih ke arsitektur yang lebih kuat seperti Transformer, agar sistem mampu menghasilkan ringkasan abstraktif berkualitas tinggi bahkan dari teks artikel lengkap.

## 7.2 Perbandingan Kinerja ROUGE



Gambar 7.3 Perbandingan Kinerja ROUGE

Gambar 7.3 menjelaskan hasil evaluasi menggunakan metrik ROUGE, terlihat perbedaan signifikan dalam kualitas ringkasan yang dihasilkan oleh model ketika diberikan dua jenis input yang berbeda. Ketika model dilatih dengan input berupa ringkasan ekstraktif, skor ROUGE-1, ROUGE-2, dan ROUGE-L masing-masing mencapai 0,5439, 0,3492, dan 0,5205, yang secara konsisten jauh lebih tinggi dibandingkan dengan skor yang diperoleh saat menggunakan teks artikel lengkap sebagai input, yaitu 0,4123, 0,2201, dan 0,3793.

Perbedaan ini menunjukkan bahwa model berbasis Bi-GRU encoder, Bahdanau additive attention, dan LSTM decoder jauh lebih efektif dalam

menghasilkan ringkasan abstraktif yang mendekati referensi ketika inputnya telah melalui penyaringan awal dan hanya berisi kalimat-kalimat inti. Skor ROUGE-1 yang lebih tinggi mengindikasikan bahwa model lebih mampu memilih kata-kata yang relevan; ROUGE-2 yang lebih baik mencerminkan kemampuan menghasilkan urutan kata yang koheren dan sesuai struktur kalimat, sementara ROUGE-L yang unggul menunjukkan bahwa model mampu mempertahankan alur naratif dan esensi makna secara lebih utuh.

Sebaliknya, ketika dihadapkan pada teks artikel utuh yang panjang dan mengandung banyak informasi sekunder, model mengalami kesulitan dalam mengidentifikasi konten penting dan menyusunnya menjadi ringkasan yang koheren, sehingga performanya menurun pada semua aspek yang diukur oleh ROUGE. Temuan ini menguatkan hipotesis bahwa kompleksitas input secara langsung memengaruhi kemampuan model abstraktif berbasis RNN dalam menangkap dan merekonstruksi makna, serta menyoroti pentingnya strategi preprocessing atau arsitektur model yang lebih canggih untuk menangani tugas ringkasan end-to-end dari teks utuh.

Selain memberikan kontribusi teknis dalam pengembangan metode peringkasan teks berbahasa Indonesia, penelitian ini juga dapat dipandang melalui perspektif nilai-nilai Islam yang tercermin dalam ayat-ayat Al-Qur'an. Allah berfirman:

إِنَّ رَبَّكُمُ اللَّهُ الَّذِي خَلَقَ السَّمَوَاتِ وَالْأَرْضَ فِي سِتَّةِ أَيَّامٍ ثُمَّ اسْتَوَىٰ عَلَى الْعَرْشِ يُدِيرُ الْأَمْرَ مَا مِنْ شَيْءٍ إِلَّا مِنْ بَعْدِ إِذْنِهِ ذَلِكُمْ اللَّهُ رَبُّكُمْ فَاعْبُدُوهُ أَفَلَا تَذَكَّرُونَ (يونس: ٣)

*Artinya: “Sesungguhnya Tuhanmu adalah Allah yang menciptakan langit dan bumi dalam enam masa, kemudian Dia berkuasa atas ‘Arasy (seraya) mengatur segala urusan. Tidak ada seorang pun pemberi syafaat, kecuali setelah (mendapat) izin-Nya. Itulah Allah, Tuhanmu. Maka, sembahlah Dia! Apakah kamu tidak mengambil pelajaran?” (Yunus: 3).*

Dalam Tafsir *Tahlili* ayat ini Allah telah menerangkan bahwa Dialah yang mengatur pergerakan planet dan benda-benda langit sehingga tidak saling bertabrakan, serta mengelola seluruh urusan makhluk-Nya dengan ketelitian yang sempurna. Dia pula yang telah menciptakan bumi dan segala isi yang terkandung didalamnya. Semuanya diciptakan dalam enam masa yang hanya Allah sendiri yang mengetahui berapa lama waktu enam masa yang dimaksud itu. (Kementerian Agama RI, 2010).

Pengembangan teknologi peringkasan teks ini merupakan wujud nyata dari *mu'amalah ma'a Allah*, yaitu interaksi hamba dengan Sang Pencipta melalui aktivitas intelektual. Allah mengajak manusia untuk melakukan *tafakkur* atau perenungan mendalam atas keteraturan alam semesta yang dikelola-Nya dengan ketelitian sempurna. Penelitian ilmiah yang mengandalkan akal dan berpikir kritis untuk menelaah fenomena, termasuk dalam menciptakan sistem algoritma yang teratur, dipandang sebagai cara manusia mengambil pelajaran dari tanda-tanda kebesaran Allah.

Sejalan dengan itu, Islam juga menekankan pentingnya amal yang bermanfaat sepanjang kehidupan manusia. Hal ini ditegaskan dalam hadist Nabi Muhammad ketika beliau ditanya:

يَا رَسُولَ اللَّهِ مَنْ خَيْرُ النَّاسِ؟ قَالَ: مَنْ طَالَ عُمْرُهُ وَحَسَنَ عَمَلُهُ

*Artinya : “Wahai Rasulullah, siapakah sebaik-baik manusia?” Beliau menjawab: “Orang yang panjang umurnya dan baik amalannya.” (HR. Tirmidzi).*

Hadis ini menunjukkan bahwa nilai terbaik manusia bukan diukur dari lamanya hidup saja, melainkan dari manfaat dan kebaikan yang ia hasilkan (Awwad Al-Khalaf, 2016). Dalam konteks *mu'amalah ma'a an-nas*, yakni hubungan baik antar sesama manusia yang berorientasi pada kemanfaatan sosial. Implementasi model peringkasan otomatis ini menjadi bentuk amal nyata yang mempermudah masyarakat dalam mengakses serta memahami informasi berita secara cepat dan efisien. Oleh karena itu, kontribusi teknis ini tidak hanya memiliki nilai akademis, tetapi juga menjadi ladang kebaikan yang berkelanjutan dan selaras dengan prinsip Islam untuk selalu menebar manfaat bagi sesama dalam kehidupan bermasyarakat.

## BAB VIII

### KESIMPULAN DAN SARAN

#### 8.1 Kesimpulan

Penelitian ini berhasil mengembangkan model peringkasan abstraktif berbasis arsitektur RNN terdiri dari *encoder* Bi-GRU, dan *decoder* LSTM, yang mampu menghasilkan ringkasan teks berbahasa Indonesia dengan tingkat koherensi dan struktur yang lumayan baik, sebagaimana terlihat dari skor ROUGE yang lebih tinggi saat model dilatih menggunakan *input* ringkasan ekstraktif (ROUGE-1: 0.5439, ROUGE-L: 0.5205). Namun, ketika diuji dengan *input* teks artikel lengkap, performa model menurun signifikan (ROUGE-1: 0.4123, ROUGE-L: 0.3793), menunjukkan bahwa model masih kesulitan menyaring informasi penting dan mempertahankan kohesi dalam teks panjang tanpa *preprocessing*. Temuan ini mengonfirmasi bahwa tantangan teknis seperti penghindaran repetisi dan pemeliharaan akurasi informasi belum sepenuhnya teratasi dalam konteks bahasa Indonesia, namun model ini telah menjadi fondasi awal yang dapat dikembangkan lebih lanjut melalui integrasi arsitektur hierarkis atau *pre-trained language* model.

Dengan ini ada beberapa poin yang dapat disimpulkan :

- a. Mengembangkan model peringkasan abstraktif berbasis RNN Arsitektur Bi-GRU dan LSTM telah diimplementasikan dan diuji secara empiris, serta berhasil menghasilkan ringkasan abstraktif yang koheren.
- b. Mengeksplorasi integrasi antara *encoder* Bi-GRU dan *decoder* LSTM, meskipun kapasitasnya masih terbatas untuk teks panjang terbukti dengan hasil yang lebih rendah jika menggunakan teks artikel langsung.

## 8.2 Saran

Penelitian mengenai pengembangan model peringkasan teks abstraktif bahasa Indonesia berbasis pendekatan *hybrid*, menggabungkan ekstraktif sebagai *input* terfokus dan RNN (BiGRU–LSTM) sebagai model *generative*, masih memiliki ruang pengembangan yang cukup luas. Meskipun hasil yang diperoleh telah menunjukkan performa yang menjanjikan, berbagai aspek teknis dan metodologis dapat terus ditingkatkan untuk menghasilkan model yang lebih akurat dan stabil. Oleh karena itu, beberapa saran berikut dapat dipertimbangkan untuk penelitian selanjutnya:

- a. Memperbaiki preprocessing ekstraktif dengan menggunakan metode Transformer.
- b. Tambahkan mekanisme hierarchical attention, agar model bisa memproses teks dalam level kalimat dan paragraf, bukan hanya token.
- c. Evaluasi dengan metrik human-centric, selain ROUGE, tambahkan evaluasi kualitatif (misalnya fluency, informativeness, readability) karena ROUGE tidak selalu mencerminkan kualitas semantik atau kenyamanan pembaca.



## DAFTAR PUSTAKA

- Adelia, R., Suyanto, S., & Wisesty, U. N. (2019). Indonesian abstractive text summarization using bidirectional gated recurrent unit. *Procedia Computer Science*, 157, 581–588. <https://doi.org/10.1016/j.procs.2019.09.017>
- Alasadi, S. A., & Bhaya, W. S. (2017). Review of data preprocessing techniques in data mining. *Journal of Engineering and Applied Sciences*, 12(16), 4102–4107.
- al-Bukhari. (2025, Januari 7). *Hadits Aku diutus untuk menyempurnakan akhlak yang mulia*. Tazkia Hadits Digital.
- Alfin, M., Abidin, Z., & Basid, P. M. N. S. A. (2024). Peringkasan Multi Dokumen Berbahasa Indonesia Menggunakan Metode Recurrent Neural Network. *Techno.Com*, 23(1), 187–197. <https://doi.org/10.62411/tc.v23i1.9605>
- Astuti, R. H., Muljono, M., & Sutriawan, S. (2024). Indonesian News Text Summarization Using MBART Algorithm. *Scientific Journal of Informatics*, 11(1), 155–164. <https://doi.org/10.15294/sji.v11i1.49224>
- Awwad Al-Khalaf. (2016). *Empat Ratus Delapan Hadist Pilihan Kutubus Sittah*. Pustaka Arafan.
- Ay, B., Ertam, F., Fidan, G., & Aydin, G. (2023). Turkish abstractive text document summarization using text to text transfer transformer. *Alexandria Engineering Journal*, 68, 1–13. <https://doi.org/10.1016/j.aej.2023.01.008>
- Bahari, A., & Dewi, K. E. (2024). *Peringkasan Teks Otomatis Abstraktif Menggunakan Transformer Pada Teks Bahasa Indonesia*. 13(1).
- Delibaş, E. (2025). Efficient TF-IDF method for alignment-free DNA sequence similarity analysis. *Journal of Molecular Graphics and Modelling*, 137, 109011. <https://doi.org/10.1016/j.jmgm.2025.109011>
- Departemen Agama Republik Indonesia. (2019). *Al-Qur'an dan Terjemahannya*. Departemen Agama RI.
- Dewi, K. E., & Widiastuti, N. I. (2022). The Design of Automatic Summarization of Indonesian Texts Using a Hybrid Approach. *Jurnal Teknologi Informasi dan Pendidikan*, 15(1), 37–43. <https://doi.org/10.24036/jtip.v15i1.451>
- Faisal, M., Halmahera, S., Cahyani, V. O., Aziz, A., Afrah, A. S., & Supriyono. (2024). Advanced Extractive Summarization of Indonesian Texts Using LSTM Models. *2024 8th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, 58–63. <https://doi.org/10.1109/ICITISEE63424.2024.10730507>

- Hartawan, G., Maylawati, D. S., & Uriawan, W. (2024). Bidirectional and Auto-Regressive Transformer (BART) for Indonesian Abstractive Text Summarization. *Jurnal Informatika Polinema*, 10(4), 535–542. <https://doi.org/10.33795/jip.v10i4.5242>
- Hendry, H., Tukino, T., Sedyono, E., Fauzi, A., & Huda, B. (2025). HyEWCos: A Comparative Study of Hybrid Embedding and Weighting Techniques for Text Similarity in Short Subjective Educational Text. *Information*, 16(11), 995. <https://doi.org/10.3390/info16110995>
- Indriati, I., Rahayudi, B., & Dewi, C. (2021). Analisis Sentimen Mengenai Moda Raya Terpadu (MRT) Jakarta dengan Metode BM25 dan K-Nearest Neighbor. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 8(2), 389–394. <https://doi.org/10.25126/jtiik.2021824508>
- Juditha, C. (2013). News Accuracy in Online Journalism (News of Alleged Corruption The Constitutional Court in Detiknews). Dalam *Jurnal Pekommas* (Vol. 16, Nomor 3).
- Kementerian Agama RI. (2010). *Mukadimah al-Qur'an dan tafsirnya*. Kementerian Agama Republik Indonesia.
- Khairunnisa, S., Adiwijaya, A., & Faraby, S. Al. (2021). Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19). *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 5(2), 406. <https://doi.org/10.30865/mib.v5i2.2835>
- Khasanah, A. N., & Hayaty, M. (2023). Abstractive-Based Automatic Text Summarization On Indonesian News Using Gpt-2. *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, 10(1), 9–18. <https://doi.org/10.33330/jurteks.v10i1.2492>
- Kramer, K. (2024). *Comparative Analysis of Document-Level Embedding Methods for Similarity Scoring on Shakespeare Sonnets and Taylor Swift Lyrics*. <https://arxiv.org/abs/2412.17552>
- Laksana, M. D. B., Karyawati, A. E., Putri, L. A. A. R., Santiyasa, I. W., ER, N. A. S., & Kadnyanan, I. G. A. G. A. (2022). Text Summarization terhadap Berita Bahasa Indonesia menggunakan Dual Encoding. *Jurnal Elektronik Ilmu Komputer Udayana*.
- Liu, W., Gao, Y., Li, J., & Yang, Y. (2021). A Combined Extractive With Abstractive Model for Summarization. *IEEE Access*, 9, 43970–43980. <https://doi.org/10.1109/ACCESS.2021.3066484>

- Lucky, H., & Suhartono, D. (2022). Investigation Of Pre-Trained Bidirectional Encoder Representations From Transformers Checkpoints For Indonesian Abstractive Text Summarization. *Journal of Information and Communication Technology*, 21(1), 71–94. <https://doi.org/10.32890/jict2022.21.1.4>
- Mohammad Masum, A. K., Abujar, S., Islam Talukder, M. A., Azad Rabby, A. K. M. S., & Hossain, S. A. (2019). Abstractive method of text summarization with sequence to sequence RNNs. *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, 1–5. <https://doi.org/10.1109/ICCCNT45670.2019.8944620>
- Mustaqhfiri, M., Abidin, Z., & Kusumawati, R. (2012). Peringkasan Teks Otomatis Berita Berbahasa Indonesia Menggunakan Metode Maximum Marginal Relevance. *MATICS*. <https://doi.org/10.18860/mat.v0i0.1578>
- Nur, E. (2021). *Peran Media Massa Dalam Menghadapi Serbuan Media Online The Role Of Mass Media In Facing Online Media Attacks*.
- Nuri, Afrizal Tjoetra, & Fahrimal, Y. (2024). Analisis Framing Pada Media Detikcom dan CNN Indonesia Terhadap Pemberitaan Konflik Pulau Rempang. *Jurnal Publish (Basic and Applied Research Publication on Communications)*, 3(1), 1–19. <https://doi.org/10.35814/publish.v3i1.6041>
- Pati, S. P., & Rautray, R. (2024). Sentence Selection for Extractive Text Summarization using TOPSIS Approach. *Procedia Computer Science*, 235, 1532–1538. <https://doi.org/10.1016/j.procs.2024.04.144>
- Pramudi Ismi, D., Ardianto, F., Dahlan, A., & Selatan, J. R. (2019). Peringkasan Ekstraktif Teks Bahasa Indonesia dengan Pendekatan Unsupervised Menggunakan Metode Clustering. *CYBERNETICS*, 3(02), 90–99.
- Raihanunnisa, F., Arhami, M., & Hidayat, R. (2023). Pendekatan Hybrid Pada Sistem Peringkasan Teks Artikel Berita Bahasa Inggris Menggunakan Natural Language Processing. *Jurnal Telematika MKOM*. <https://journal.budiluhur.ac.id/index.php/telematika/>
- Ranggianto, N. A., Purwitasari, D., Fatichah, C., & Sholikhah, R. W. (2023). Abstractive and Extractive Approaches for Summarizing Multi-document Travel Reviews. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(6), 1464–1475. <https://doi.org/10.29207/resti.v7i6.5170>
- Rusi, I., Muhandi, M., Arsyandi, R. R., & Ayu, M. (2023). *Sosialisasi Pentingnya Literasi Dini Dan Menyaring Informasi Pada Siswa MI Raudlatul Mubta'diin*. <https://doi.org/10.31604/jpm.v6i11.4021-4029>
- Setiawan, A. Y. S. A., & Alexander, E. (2023). *Pengujian Algoritma TextRank Dalam Merangkum Teks*.

- Severina, V., & Khodra, M. L. (2019). Multidocument Abstractive Summarization using Abstract Meaning Representation for Indonesian Language. *International Conference of Advanced Informatics: Concepts, Theory and Applications (ICAICTA)*, 1–6.
- Suleiman, D., & Awajan, A. (2020). Deep Learning Based Abstractive Text Summarization: Approaches, Datasets, Evaluation Measures, and Challenges. *Mathematical Problems in Engineering*, 2020. <https://doi.org/10.1155/2020/9365340>
- UÇKAN, T. (2025). A hybrid model for extractive summarization: Leveraging graph entropy to improve large language model performance. *Ain Shams Engineering Journal*, 16(5), 103348. <https://doi.org/10.1016/j.asej.2025.103348>
- Wang, W., Wei, F., Dong, L., Bao, H., Yang, N., & Zhou, M. (2020). *MiniLM: Deep Self-Attention Distillation for Task-Agnostic Compression of Pre-Trained Transformers*. <https://arxiv.org/abs/2002.10957>
- Widyassari, A. P., Rustad, S., Shidik, G. F., Noersasongko, E., Syukur, A., Affandy, A., & Setiadi, D. R. I. M. (2022). Review of automatic text summarization techniques & methods. Dalam *Journal of King Saud University - Computer and Information Sciences* (Vol. 34, Nomor 4, hlm. 1029–1046). King Saud bin Abdulaziz University. <https://doi.org/10.1016/j.jksuci.2020.05.006>
- Yanuarti, R., & Alfaruq, H. A. (2022). *Implementasi Text Summarization Pada Reading Comprehension Menggunakan Library Python*.
- Yaswanth, Y., Hrushikesh, T., & Sheela, J. (2023). *Abstractive text summarization using deep RNN*. 050022. <https://doi.org/10.1063/5.0168209>
- Yuliska, Y., & Syaliman, K. U. (2020). Literatur Review Terhadap Metode, Aplikasi dan Dataset Peringkasan Dokumen Teks Otomatis untuk Teks Berbahasa Indonesia. *IT Journal Research and Development*, 5(1), 19–31. [https://doi.org/10.25299/itjrd.2020.vol5\(1\).4688](https://doi.org/10.25299/itjrd.2020.vol5(1).4688)
- Zamzam, M. A., Crysdian, C., & Holle, K. F. H. (2020). Sistem Automatic Text Summarization Menggunakan Algoritma Textrank. *MATICS*, 12(2), 111–116. <https://doi.org/10.18860/mat.v12i2.8372>