

BAB II

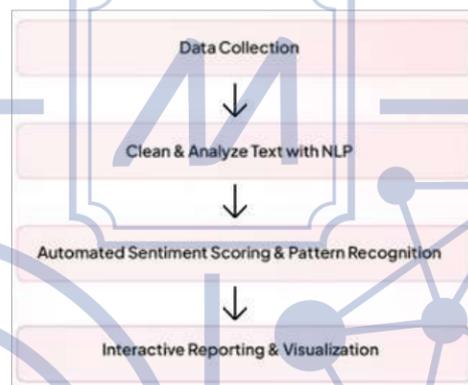
KAJIAN LITERATUR

2.1 Tinjauan Pustaka

Pada sub bab ini, akan dijabarkan teori dan kajian ilmiah yang berhubungan dengan penelitian yang dilakukan.

2.1.1 Analisis Sentimen

Analisis sentimen adalah proses mengidentifikasi, mengekstrak, dan mengklasifikasikan opini, emosi, atau sikap dari data teks (seperti ulasan, komentar, atau *tweet*) ke dalam kategori positif, negatif, atau netral [13]. Gambar 2.1 menunjukkan tahapan proses dalam analisis sentimen secara umum.



Gambar 2. 1 Proses Analisis Sentimen

Berikut adalah penjelasan dari Gambar 2.1 [14]:

1. Pengumpulan Data (*Data Collection*)

Tahap pertama dalam proses analisis sentimen adalah mengumpulkan data teks dari berbagai sumber. Data ini bisa berasal dari:

- a. Media sosial (seperti *Twitter*, *Facebook*, *Instagram*)
- b. Ulasan pelanggan (*review* produk/jasa)
- c. Komentar di *platform* daring
- d. Kuesioner atau formulir umpan balik

Tujuan dari tahap ini adalah memperoleh data yang relevan dan cukup banyak untuk dianalisis secara representatif.

2. Pembersihan & Analisis Teks dengan NLP (*Clean & Analyze Text with NLP*)

Setelah data terkumpul, langkah selanjutnya adalah pra-pemrosesan dan analisis teks menggunakan teknik *Natural Language Processing* (NLP). Proses ini meliputi:

- a. Pembersihan teks: menghapus karakter khusus, tanda baca, angka, stopwords, dan konten tidak relevan lainnya
- b. Tokenisasi: memecah teks menjadi kata-kata atau unit-unit yang lebih kecil
- c. *Stemming* atau *Lemmatization*: mengubah kata ke bentuk dasar
- d. *POS Tagging*: mengenali jenis kata (kata benda, kata kerja, dll.)
- e. *Named Entity Recognition* (NER): mengenali entitas penting seperti nama orang, lokasi, dan organisasi

Tahap ini bertujuan untuk menyiapkan teks mentah agar bisa diolah lebih lanjut dalam proses klasifikasi sentimen.

3. Skoring Sentimen Otomatis & Pengenalan Pola (*Automated Sentiment Scoring & Pattern Recognition*)

Pada tahap ini, sistem secara otomatis melakukan analisis sentimen terhadap teks yang telah dibersihkan. Ini bisa dilakukan menggunakan model pembelajaran mesin atau pembelajaran mendalam seperti:

- a. Klasifikasi sentimen (positif, negatif, netral)
- b. Deteksi pola atau tren umum yang sering muncul dalam data
- c. Topik modeling, untuk mengelompokkan komentar berdasarkan tema

Tujuan utama dari tahap ini adalah memahami opini publik atau persepsi pengguna secara otomatis dan sistematis.

4. Pelaporan & Visualisasi Interaktif (*Interactive Reporting & Visualization*)

Tahap terakhir adalah menyajikan hasil analisis dalam bentuk yang mudah dipahami melalui:

- a. *Dashboard* interaktif
- b. Grafik batang, diagram lingkaran, *word cloud*, *heatmap*, dan visualisasi lainnya
- c. Tren waktu (misalnya: sentimen dari bulan ke bulan)

Visualisasi ini sangat berguna bagi pemangku kepentingan untuk mengambil keputusan berbasis data (*data-driven decision making*).

Tujuan utama dari analisis sentimen adalah untuk memahami persepsi publik terhadap suatu produk, layanan, atau kebijakan; mengukur tingkat kepuasan pengguna terhadap layanan tertentu; mendukung proses pengambilan keputusan berbasis data yang

lebih akurat; serta mendeteksi secara dini berbagai permasalahan atau keluhan yang muncul dalam interaksi publik [15].

Ada dua pendekatan utama dalam analisis sentimen [16]:

1. *Lexicon-Based* (Berdasarkan Kamus Sentimen)

Menggunakan daftar kata (*lexicon*) yang sudah diberi label sentimen (contoh: "bagus" = positif, "buruk" = negatif).

Kelebihan:

- a. Tidak memerlukan data latih.
- b. Cocok untuk domain umum.

Kekurangan: Kurang akurat untuk konteks spesifik (misalnya, slang atau bahasa informal).

2. *Machine Learning-Based* (Berdasarkan Pembelajaran Mesin)

Menggunakan algoritma seperti *Naive Bayes*, *SVM*, atau *Neural Networks* untuk mempelajari pola dari data teks yang sudah diberi label.

Kelebihan:

- a. Lebih akurat untuk domain spesifik.
- b. Bisa menangkap konteks yang kompleks.

Kekurangan:

- a. Membutuhkan data latih yang besar.
- b. Proses pelatihan memakan waktu.

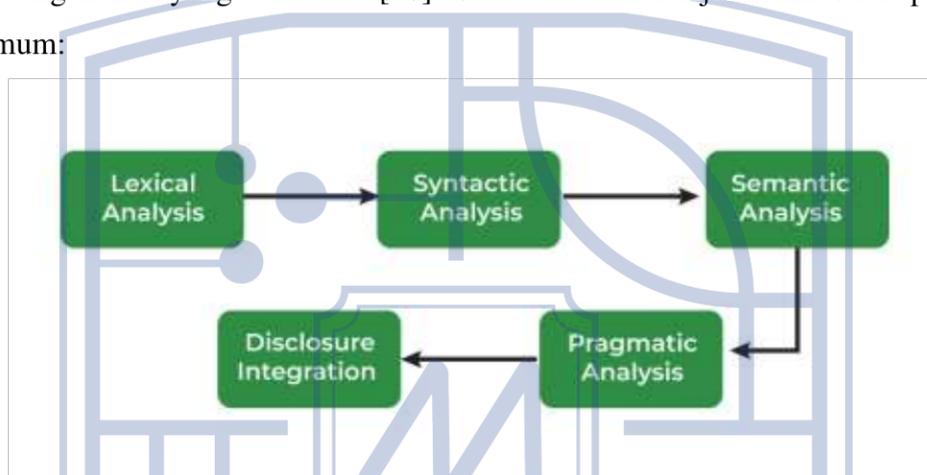
Analisis sentimen memiliki peran yang signifikan dalam evaluasi layanan publik karena mampu memberikan pemantauan terhadap tingkat kepuasan masyarakat, sehingga pemerintah atau penyedia layanan dapat memahami respons publik terhadap berbagai sektor seperti transportasi, kesehatan, dan administrasi. Selain itu, analisis ini memungkinkan identifikasi dini terhadap permasalahan, misalnya keluhan mengenai pelayanan yang lambat atau kurang ramah yang terekam melalui media sosial maupun survei. Analisis sentimen juga berkontribusi dalam meningkatkan akuntabilitas, di mana hasilnya dapat dijadikan dasar evaluasi untuk perbaikan kebijakan. Lebih jauh, pendekatan ini mendukung pengambilan keputusan yang berbasis data (*data-driven*), sehingga kebijakan yang diambil tidak semata-mata berdasarkan asumsi, melainkan pada bukti empirik mengenai persepsi dan kebutuhan masyarakat [17].

Analisis sentimen adalah alat penting untuk memahami opini publik, terutama dalam konteks layanan publik. Dengan pendekatan *lexicon-based* atau *machine learning*,

organisasi dapat mengukur kepuasan pengguna dan mengambil tindakan perbaikan yang lebih efektif.

2.1.2 Pemrosesan Bahasa Alami (*Natural Language Processing / NLP*)

Pemrosesan Bahasa Alami (NLP) adalah cabang dari kecerdasan buatan (AI) yang berfokus pada interaksi antara komputer dan bahasa manusia. NLP bertujuan untuk memungkinkan komputer memahami, memproses, dan menghasilkan teks dalam bahasa manusia dengan cara yang bermakna [18]. Gambar 2.2 menunjukkan ilustrasi proses NLP secara umum:



Gambar 2. 2 Proses NLP

Berikut adalah penjelasan dari Gambar 2.2 [19]:

1. Analisis Leksikal (*Lexical Analysis*)

Tahap pertama dari proses NLP adalah analisis leksikal, yaitu proses memecah teks ke dalam unit-unit linguistik terkecil yang disebut token. Tokenisasi merupakan bagian utama dari tahap ini, yang memisahkan kata, frasa, atau simbol dari teks mentah. Selain itu, tahap ini juga mencakup identifikasi bentuk dasar kata (melalui *stemming* atau *lemmatisasi*) dan pembersihan teks dari karakter yang tidak relevan. Tujuan dari analisis leksikal adalah menyusun input linguistik dasar bagi tahap analisis selanjutnya.

2. Analisis Sintaktik (*Syntactic Analysis*)

Analisis sintaktik bertujuan untuk memeriksa struktur gramatikal dari teks. Dalam tahap ini, sistem NLP menentukan bagaimana kata-kata disusun dalam kalimat berdasarkan aturan tata bahasa (*grammar rules*). Proses seperti *part-of-speech tagging* (penandaan jenis kata) dan pembuatan *parse tree* dilakukan untuk memahami relasi struktural antar-kata. Hasil dari tahap ini adalah struktur sintaksis yang valid dan dapat digunakan untuk interpretasi makna kalimat.

3. Analisis Semantik (*Semantic Analysis*)

Tahap ini berfokus pada pemberian makna terhadap elemen linguistik dalam kalimat. Analisis semantik mengaitkan struktur sintaktik dengan makna sebenarnya dari kata dan frasa dalam konteks kalimat. Proses ini mencakup interpretasi hubungan makna antara subjek, predikat, dan objek, serta identifikasi entitas atau konsep penting yang dibahas dalam teks. Dengan demikian, analisis semantik memungkinkan mesin untuk memahami isi pesan secara literal.

4. Analisis Pragmatik (*Pragmatic Analysis*)

Setelah memperoleh pemahaman literal dari suatu kalimat, sistem perlu memahami konteks situasional dari komunikasi tersebut. Analisis pragmatik mempertimbangkan aspek-aspek eksternal seperti siapa pembicara, siapa pendengar, waktu, tempat, serta maksud dan tujuan dari ujaran. Misalnya, kalimat “Bisa tolong tutup pintunya?” secara literal adalah pertanyaan, namun secara pragmatik merupakan permintaan. Analisis ini penting dalam membedakan makna eksplisit dan implisit dari suatu teks.

5. Integrasi Wacana (*Discourse Integration*)

Tahap terakhir dalam proses NLP adalah integrasi wacana, yaitu menyatukan makna dari kalimat-kalimat dalam suatu teks secara koheren. Dalam tahap ini, sistem mempertimbangkan kalimat sebelumnya untuk memahami referensi, koherensi antar-kalimat, serta kesinambungan topik pembahasan. Contohnya, penggunaan kata ganti seperti “dia” harus dihubungkan dengan entitas yang disebut sebelumnya. Integrasi wacana memungkinkan sistem NLP memahami makna teks secara keseluruhan, bukan hanya per kalimat.

Untuk bahasa Indonesia, NLP memiliki tantangan tersendiri, terutama dalam hal variasi bahasa dan ambiguitas kata. Bahasa Indonesia memiliki banyak afiks, pengulangan kata, dan variasi bentuk kata yang seringkali membuat pemrosesan lebih rumit dibandingkan dengan bahasa yang lebih standar.

2.1.3 Transformers dan Model IndoBERT

Transformer adalah model arsitektur deep learning yang diperkenalkan oleh Vaswani et al. pada tahun 2017 dalam makalah berjudul "*Attention is All You Need*". Model ini dirancang untuk menangani masalah pemrosesan urutan data, seperti teks, yang sebelumnya ditangani oleh model berbasis *Recurrent Neural Networks* (RNN) dan *Long Short-Term Memory* (LSTM). Keunggulan utama dari transformer adalah penggunaan *self-attention*

yang memungkinkan model untuk memproses seluruh urutan input secara paralel, berbeda dengan RNN yang memproses urutan secara berurutan [20].

Beberapa elemen utama dalam transformer adalah [21]:

1. *Self-attention mechanism*

Memberikan bobot kepada setiap kata dalam kalimat berdasarkan hubungan antar kata, memungkinkan model untuk memfokuskan perhatian pada kata-kata yang relevan dengan kata lainnya.

2. *Positional Encoding*

Karena transformer memproses seluruh input secara paralel, diperlukan informasi tentang urutan kata dalam kalimat, yang disertakan dengan positional encoding.

3. *Encoder-decoder architecture*

Model transformer biasanya terdiri dari dua bagian utama: *encoder* (untuk mengkodekan informasi input) dan *decoder* (untuk menghasilkan output). Dalam beberapa aplikasi, seperti klasifikasi teks, hanya bagian encoder yang digunakan.

Transformer telah menjadi dasar dari berbagai model NLP modern seperti BERT, GPT, dan T5 yang telah mengubah cara kita mengerjakan tugas NLP.

IndoBERT adalah model berbasis arsitektur *Bidirectional Encoder Representations from Transformers* (BERT) yang dikembangkan khusus untuk bahasa Indonesia. Model ini dirancang untuk memahami teks dalam bahasa Indonesia dengan lebih baik, mengingat tantangan-tantangan unik dalam bahasa ini seperti afiks, konjugasi, dan variasi bahasa [22].

Karakteristik utama dari IndoBERT adalah [23]:

1. *Pretrained on Indonesian Corpus*

IndoBERT dilatih pada kumpulan data teks bahasa Indonesia yang besar dan beragam, seperti berita, Wikipedia, dan korpus digital lainnya. Ini memungkinkan model untuk memahami nuansa bahasa Indonesia.

2. *BERT-based architecture*

Menggunakan pendekatan *encoder* dari BERT, yang bersifat *bidirectional*, memungkinkan model untuk memahami konteks penuh dari kalimat, baik dari sisi kiri maupun kanan.

3. *Fine-tuning for specific tasks*

IndoBERT dapat disesuaikan (*fine-tuned*) untuk berbagai tugas NLP spesifik, seperti klasifikasi teks, analisis sentimen, dan pengenalan entitas bernama.

IndoBERT memiliki beberapa keunggulan dalam menangani teks bahasa Indonesia dibandingkan dengan model NLP umum, karena penyesuaian khusus untuk morfologi dan sintaksis bahasa Indonesia.

IndoBERT berperan penting dalam berbagai tugas NLP yang melibatkan teks bahasa Indonesia, antara lain [24]:

1. Klasifikasi Teks

IndoBERT dapat digunakan untuk mengklasifikasikan teks ke dalam kategori yang telah ditentukan, seperti analisis sentimen, klasifikasi berita, atau deteksi *spam*.

2. Pengenalan Entitas Bernama (NER)

Model ini dapat mengenali entitas penting dalam teks, seperti nama orang, tempat, organisasi, atau waktu.

3. Analisis Sentimen

IndoBERT sangat efektif dalam menganalisis sentimen dalam teks bahasa Indonesia, apakah teks tersebut positif, negatif, atau netral.

4. Penerjemahan Mesin

Meskipun lebih sering digunakan untuk tugas-tugas seperti klasifikasi dan NER, IndoBERT juga bisa digunakan untuk menerjemahkan teks antarbahasa, khususnya dalam konteks bahasa Indonesia.

5. Penyusunan Ringkasan

Model ini bisa digunakan untuk menghasilkan ringkasan dari teks panjang, misalnya, artikel atau laporan.

Keunggulan IndoBERT terletak pada kemampuannya untuk memahami konteks kalimat dalam bahasa Indonesia yang memiliki struktur kalimat yang berbeda dengan bahasa Inggris.

Dalam penerapan model NLP, terdapat dua pendekatan utama untuk menggunakan model *pre-trained* seperti IndoBERT: *fine-tuning* dan *feature extraction*.

1. *Fine-Tuning* [25]

Proses: Pada *fine-tuning*, model *pre-trained*, seperti IndoBERT, dilatih lebih lanjut dengan dataset yang lebih kecil dan spesifik untuk tugas tertentu. Seluruh model (termasuk layer-layer terakhir) dioptimalkan untuk mempelajari pola dari data baru.

Keuntungan: *Fine-tuning* memungkinkan model untuk belajar secara lebih mendalam dan menyesuaikan bobot internalnya dengan baik untuk tugas spesifik, yang dapat meningkatkan performa pada tugas tertentu.

Kekurangan: Proses *fine-tuning* memerlukan data pelatihan tambahan dan lebih banyak sumber daya komputasi, serta dapat berisiko *overfitting* jika data pelatihan terbatas.

2. *Feature Extraction (Transfer Learning)* [26]

Proses: Dalam pendekatan *feature extraction*, model *pre-trained* seperti IndoBERT digunakan sebagai *extractor* fitur, di mana representasi (*embedding*) yang dihasilkan oleh model digunakan sebagai input untuk model lain yang lebih sederhana atau algoritma *machine learning* (seperti SVM atau *Logistic Regression*).

Keuntungan: Pendekatan ini lebih cepat dan memerlukan sumber daya yang lebih sedikit, karena hanya layer terakhir model yang dilatih atau digunakan untuk membangun model baru.

Kekurangan: Meskipun lebih cepat, pendekatan ini mungkin tidak seefektif *fine-tuning* dalam memaksimalkan performa pada tugas tertentu, terutama jika data pelatihan memiliki perbedaan yang signifikan dari data yang digunakan untuk *pre-training*.

2.1.4 Transfer Learning dalam NLP

Transfer learning adalah pendekatan dalam machine learning di mana pengetahuan yang diperoleh dari satu tugas atau domain digunakan untuk meningkatkan kinerja pada tugas atau domain lain yang serupa, namun mungkin memiliki data terbatas. Dalam konteks *Natural Language Processing (NLP)*, *transfer learning* sering kali melibatkan penggunaan model yang telah dilatih pada kumpulan data besar (*pre-trained models*) dan menyesuaikannya untuk tugas atau data spesifik yang lebih kecil [27].

Dalam NLP, *transfer learning* umumnya dilakukan dengan menggunakan model berbasis transformer seperti BERT, GPT, atau T5 yang telah dilatih pada korpus teks besar dan kemudian disesuaikan untuk berbagai tugas NLP seperti analisis sentimen, klasifikasi teks, atau penerjemahan [28].

Pada NLP, implementasi transfer learning sering melibatkan penggunaan model berbasis *transformer* yang telah dilatih dengan menggunakan jumlah data yang sangat besar (seperti Wikipedia atau *Common Crawl*). Proses transfer learning dengan model transformer umumnya dilakukan dalam dua tahap utama:

1. *Pre-training* (Pelatihan Awal) [29]

Pada tahap ini, model *transformer* dilatih pada data yang sangat besar tanpa penyesuaian khusus untuk tugas tertentu. Model ini belajar untuk menangkap informasi bahasa yang lebih umum seperti sintaksis, semantik, dan hubungan antar kata.

Contoh model *pre-trained* yang populer adalah BERT (*Bidirectional Encoder Representations from Transformers*), GPT (*Generative Pretrained Transformer*), dan T5 (*Text-to-Text Transfer Transformer*). Model-model ini menggunakan dataset teks besar untuk memahami konteks dan struktur bahasa secara umum.

2. *Fine-tuning* (Penyesuaian Tugas Spesifik) [30]

Setelah *pre-training*, model diterapkan pada tugas NLP yang lebih spesifik, seperti analisis sentimen, klasifikasi teks, atau pengenalan entitas bernama (NER).

Pada tahap ini, hanya bagian terakhir dari model yang diubah atau dilatih lebih lanjut menggunakan data yang lebih kecil dan lebih relevan dengan tugas yang diinginkan. Proses *fine-tuning* ini memungkinkan model untuk mengadaptasi pengetahuan umum yang telah diperoleh dari *pre-training* untuk tugas yang lebih spesifik.

Contoh penerapan *transfer learning* pada model *transformer* adalah penggunaan BERT untuk analisis sentimen. Model BERT awalnya dilatih dengan data teks yang sangat besar (*pre-training*) dan kemudian di *fine-tune* dengan data sentimen spesifik (misalnya, *tweet* yang dikategorikan sebagai positif atau negatif) untuk meningkatkan performa dalam tugas analisis sentimen.

Secara keseluruhan, *transfer learning* telah membawa banyak kemajuan dalam NLP dan memungkinkan model untuk diadaptasi dengan efisien untuk berbagai tugas meskipun data terbatas, namun penting untuk memperhatikan keterbatasan yang ada dalam mengimplementasikan teknik ini [31].

2.1.5 *Random Forest*

Random Forest adalah algoritma *machine learning* berbasis *ensemble* yang menggabungkan banyak *decision trees* untuk membuat prediksi yang lebih akurat dan stabil. Konsep dasarnya adalah menggabungkan beberapa model (dalam hal ini, *decision trees*) untuk memperbaiki kinerja model secara keseluruhan. *Random Forest* termasuk dalam kategori *supervised learning*, di mana model dilatih menggunakan data berlabel untuk memprediksi label atau kategori dari data baru [32].

Keunggulan utama *Random Forest* adalah kemampuannya untuk mengurangi *overfitting* yang sering terjadi pada *decision trees tunggal*, dengan menggunakan teknik *ensemble learning*, yaitu metode yang menggabungkan hasil dari beberapa model untuk meningkatkan akurasi [33].

Random Forest sering diterapkan dalam klasifikasi teks untuk berbagai tugas NLP [34], seperti klasifikasi berita [35], analisis sentimen [34], atau pengelompokan dokumen [36]. Berikut adalah cara *Random Forest* digunakan dalam klasifikasi teks [37]:

1. Representasi Teks

Sebelum menggunakan *Random Forest* untuk klasifikasi teks, teks perlu dikonversi menjadi format numerik yang dapat dipahami oleh model. Representasi yang umum digunakan adalah *bag-of-words* (BoW), TF-IDF (*Term Frequency-Inverse Document Frequency*), atau *word embeddings*.

Dalam metode BoW atau TF-IDF, setiap dokumen dianggap sebagai vektor fitur yang berisi frekuensi kemunculan kata-kata dalam dokumen tersebut, atau informasi penting tentang seberapa jarang atau sering kata tersebut muncul dalam seluruh koleksi dokumen.

2. Pelatihan Model

Setelah teks direpresentasikan sebagai vektor fitur, dataset yang terdiri dari vektor-vektor ini digunakan untuk melatih model *Random Forest*. Setiap pohon keputusan akan mencoba memisahkan teks berdasarkan fitur-fitur (kata atau term) yang ada, dan setiap pohon akan menghasilkan keputusan atau label klasifikasi.

3. Voting Mayoritas

Untuk klasifikasi, *Random Forest* akan mengumpulkan prediksi dari semua pohon keputusan. Setiap pohon memberikan hasil klasifikasi berdasarkan fitur teks yang dipelajarinya. Hasil akhir klasifikasi akan ditentukan berdasarkan voting mayoritas dari semua pohon. Ini berarti kategori yang paling sering diprediksi oleh pohon-pohon tersebut akan menjadi prediksi akhir untuk dokumen atau teks baru.

4. Keunggulan dalam Klasifikasi Teks

a. Mengurangi *Overfitting*

Dengan menggunakan banyak pohon keputusan, *Random Forest* dapat mengurangi *overfitting* yang sering terjadi pada pohon keputusan tunggal.

b. Robust terhadap Data Tidak Seimbang

Random Forest juga efektif dalam menangani dataset yang tidak seimbang, misalnya, ketika beberapa kelas lebih banyak muncul daripada yang lain, karena pohon-pohon individu akan belajar dari data yang berbeda.

c. Toleransi terhadap Data yang Hilang

Random Forest cukup tahan terhadap data yang hilang, karena setiap pohon keputusan dibangun dengan subset yang berbeda dari data.

Secara keseluruhan, *Random Forest* adalah algoritma yang sangat efektif untuk klasifikasi teks dan dapat digunakan dalam banyak aplikasi NLP, meskipun ia memiliki beberapa kekurangan yang perlu dipertimbangkan tergantung pada skala dan kompleksitas data yang dihadapi [38].

2.2 Penelitian Terkait

Berikut ini adalah ringkasan penelitian terdahulu yang digunakan sebagai referensi di dalam rancangan penelitian ini, seperti terlihat pada Tabel 2.1. di bawah ini.

Tabel 2. 1 Ringkasan Penelitian Terdahulu

Peneliti	Penelitian Yang Dilakukan	Hasil Penelitian
Alqaryouti, dkk (2024) [39]	<p>Penelitian ini bertujuan membantu entitas pemerintah memahami kebutuhan dan harapan pelanggan dengan menganalisis ulasan aplikasi pintar dan umpan balik online.</p> <p>Untuk mencapai tujuan tersebut, peneliti mengusulkan pendekatan <i>hibrid aspect-based sentiment analysis</i> yang menggabungkan leksikon domain dan aturan untuk mengekstrak aspek penting dari ulasan serta mengklasifikasikan sentimen terkait.</p> <p>Metode ini memanfaatkan teknik pemrosesan bahasa, aturan, dan leksikon untuk mengatasi berbagai tantangan analisis sentimen serta menghasilkan ringkasan hasil yang efektif.</p>	<p>Hasil penelitian menunjukkan bahwa akurasi ekstraksi aspek meningkat signifikan ketika aspek implisit turut diperhitungkan.</p> <p>Model klasifikasi terintegrasi yang diusulkan unggul 5% lebih tinggi dalam hal akurasi dibandingkan baseline berbasis leksikon dan kombinasi aturan lainnya.</p> <p>Selain itu, pendekatan ini juga mengungguli model machine learning berbasis <i>Support Vector Machine</i> (SVM).</p> <p>Namun, ketika leksikon dan aturan digunakan sebagai fitur input untuk model SVM, akurasinya lebih tinggi dibandingkan model SVM lainnya.</p>
Pikir, dkk (2021) [40]	<p>Penelitian ini bertujuan menganalisis sentimen masyarakat terhadap layanan pemerintah</p>	<p>Hasil analisis menunjukkan akurasi sebesar 55,56%, dengan</p>

	<p>berbasis teknologi di Kota Pekanbaru, khususnya yang terpusat di <i>public service mall</i>. Kritik dari netizen di media sosial seperti <i>Twitter</i> menjadi fokus untuk memahami harapan masyarakat.</p> <p>Metode yang digunakan adalah <i>Naïve Bayes Classifier</i> (NBC), sebuah pendekatan statistik yang memprediksi probabilitas sentimen (positif, negatif, atau netral) berdasarkan perhitungan kemungkinan.</p> <p>Data dibagi dengan rasio 70% (pelatihan) dan 30% (pengujian) untuk mengukur kinerja model.</p>	<p>nilai <i>precision</i> 64%, <i>recall</i> 80%, dan <i>f1-score</i> 71,2%.</p> <p>Meskipun akurasi tergolong moderat, tingginya <i>recall</i> menunjukkan kemampuan model dalam menangkap sebagian besar sentimen yang relevan, sementara <i>f1-score</i> yang cukup baik mengindikasikan keseimbangan antara <i>precision</i> dan <i>recall</i>.</p> <p>Hasil ini dapat menjadi dasar perbaikan layanan pemerintah dengan mempertimbangkan masukan masyarakat.</p>
<p>Choi, dkk (2020) [41]</p>	<p>Penelitian ini berfokus pada pengembangan model <i>sentence embedding</i> berbasis BERT dan ALBERT untuk meningkatkan kinerja pada tugas NLP seperti <i>Semantic Textual Similarity</i> (STS) dan <i>Natural Language Inference</i> (NLI).</p> <p>Peneliti memodifikasi arsitektur BERT dengan struktur siamese dan <i>triplet network</i> (<i>Sentence-BERT/SBERT</i>) serta mengganti BERT dengan ALBERT untuk menciptakan <i>Sentence-ALBERT</i> (<i>SALBERT</i>).</p>	<p>Hasil menunjukkan bahwa arsitektur CNN meningkatkan performa ALBERT secara signifikan dibandingkan BERT pada tugas STS, meskipun ALBERT memiliki parameter yang jauh lebih sedikit.</p> <p>SALBERT dengan CNN menunjukkan kompetitivitas yang tinggi terhadap BERT dalam evaluasi NLP, membuktikan bahwa efisiensi model ALBERT tidak mengorbankan kinerja.</p> <p>Temuan ini memperkuat potensi ALBERT sebagai alternatif ringan</p>

	<p>Selain itu, dieksperimenkan juga penggunaan outer CNN <i>sentence-embedding network</i> pada SBERT dan SALBERT.</p> <p>Evaluasi dilakukan menggunakan dataset STS dan NLI untuk menguji efektivitas model.</p>	<p>namun efektif untuk tugas pemrosesan bahasa alami.</p>
Nugroho, et. al (2021)	<p>Penelitian ini bertujuan menganalisis sentimen masyarakat Indonesia di <i>Twitter</i> terkait program vaksinasi Covid-19 menggunakan dua algoritma, yaitu Random Forest dan BERT.</p> <p>Tahapan penelitian meliputi pra-pemrosesan data tweet, pelabelan sentimen, penanganan data tidak seimbang, klasifikasi dataset, serta evaluasi kinerja model.</p> <p>Analisis dilakukan untuk memahami minat dan tanggapan publik terhadap vaksinasi, dengan membandingkan efisiensi dan akurasi kedua algoritma tersebut.</p>	<p>Setelah penanganan data tidak seimbang, <i>Random Forest</i> menghasilkan akurasi 81%, <i>F1-score</i> 74%, presisi 76%, dan <i>recall</i> 74%, sementara BERT mencapai akurasi 82%, <i>F1-score</i> 79%, presisi 78%, dan <i>recall</i> 79%.</p> <p>Meskipun BERT sedikit lebih unggul dalam kinerja klasifikasi, Random Forest memiliki waktu komputasi yang jauh lebih cepat dibandingkan BERT.</p> <p>Temuan ini menunjukkan bahwa pemilihan algoritma dapat disesuaikan dengan kebutuhan, apakah mengutamakan kecepatan (<i>Random Forest</i>) atau akurasi yang lebih tinggi (BERT).</p>
Saravanan, dkk (2022) [42]	<p>Penelitian ini bertujuan untuk mendeteksi dini depresi melalui analisis bahasa yang digunakan dalam pesan dan postingan media sosial.</p> <p>Beberapa algoritma <i>Machine Learning</i> seperti CNN, SVM,</p>	<p>Hasil penelitian menunjukkan bahwa model berbasis word <i>embedding</i> (BERT dan <i>FastText</i>) dapat secara efektif menganalisis pola bahasa terkait depresi.</p> <p>Pendekatan ini diharapkan dapat memberikan alat diagnosis dini</p>

	<p><i>Random Forest</i>, dan <i>Naïve Bayes</i> digunakan dengan memanfaatkan teknik word embedding BERT dan <i>FastText</i>.</p> <p>Model ini kemudian dibandingkan dengan pendekatan berbasis <i>Linguistic Metadata at the User Level</i> untuk mengevaluasi efektivitasnya dalam mengidentifikasi tanda-tanda depresi.</p>	<p>yang lebih akurat dibandingkan metode berbasis metadata linguistik tradisional.</p> <p>Kombinasi teknik <i>deep learning</i> (seperti CNN dengan BERT) dan algoritma klasik (seperti SVM dan <i>Random Forest</i>) menawarkan potensi besar dalam deteksi depresi melalui media sosial.</p>
<p>Martinez-Rodriguez, dkk (2020) [43]</p>	<p>Penelitian ini menyajikan survei komprehensif tentang penerapan teknik <i>Information Extraction</i> (IE) dalam konteks Semantic Web, dengan fokus pada dua perspektif utama:</p> <ul style="list-style-type: none"> • penggunaan sumber daya Semantic Web (seperti ontologi, basis pengetahuan, dan alat) untuk meningkatkan IE • penggunaan IE untuk mengisi/memperkaya Semantic Web. <p>Fokus utama meliputi ekstraksi dan <i>linking</i> tiga elemen kunci: entitas, konsep, dan relasi.</p> <p>Ekstraksi melibatkan identifikasi mentions (sebutan) dalam teks tidak terstruktur/semi-terstruktur, sementara <i>linking</i> menghubungkan mentions</p>	<p>Survei ini mengungkapkan bahwa integrasi IE dan Semantic Web saling memperkuat: sumber daya Semantic Web meningkatkan akurasi ekstraksi entitas dan relasi, sementara IE berkontribusi pada pengayaan basis pengetahuan Semantic Web.</p> <p>Teknik berbasis teks alami mendominasi penelitian, tetapi pendekatan khusus untuk data semi-terstruktur juga menunjukkan potensi signifikan.</p> <p>Tantangan utama termasuk disambiguasi entitas/konsep dan ekstraksi relasi yang kontekstual.</p> <p>Temuan ini menyoroti peluang pengembangan alat IE yang lebih adaptif untuk mendukung Semantic Web yang dinamis.</p>

	<p>tersebut dengan identifikasi terdisambiguasi dalam basis pengetahuan Semantic Web.</p> <p>Kajian mencakup teknik seperti <i>Named Entity Recognition</i>, <i>Entity Disambiguation</i>, <i>Terminology Extraction</i>, dan <i>Relation Extraction</i>, baik untuk teks alami maupun sumber semi-terstruktur.</p>	
Qasim, dkk (2022) [44]	<p>Penelitian ini mengeksplorasi penerapan <i>transfer learning</i> untuk masalah klasifikasi teks, khususnya pada dataset COVID-19 (<i>fake news</i> dan <i>tweet</i>) serta konten ekstremis-non-ekstremis. Tujuannya adalah menguji kinerja model berbasis <i>transfer learning</i> dalam mengkategorikan teks dari sumber seperti berita, blog, dan media sosial, yang belum banyak dieksplorasi sebelumnya.</p> <p>Metode evaluasi meliputi akurasi, <i>precision</i>, <i>recall</i>, <i>F1-score</i>, dan visualisasi <i>heat map</i> untuk analisis performa model</p>	<p>Hasil menunjukkan bahwa pendekatan <i>transfer learning</i> efektif untuk klasifikasi teks pada dataset COVID-19 dan konten ekstremis, dengan metrik kinerja (akurasi, <i>precision</i>, <i>recall</i>, <i>F1-score</i>) yang diukur secara komprehensif.</p> <p>Heat map membantu mengidentifikasi pola kesalahan klasifikasi.</p> <p>Penelitian ini juga menyoroti potensi pengembangan model lebih lanjut, seperti integrasi teknik <i>deep learning</i> atau perluasan dataset untuk meningkatkan generalisasi.</p> <p>Temuan ini mendukung penggunaan <i>transfer learning</i> dalam tugas klasifikasi teks yang kompleks dan sensitif secara kontekstual</p>
Pota, dkk (2021) [45]	<p>Penelitian ini berfokus pada analisis sentimen terhadap <i>tweet</i></p>	<p>Hasil menunjukkan bahwa strategi pra-pemrosesan yang tepat (seperti</p>

	<p>dengan mempertimbangkan tantangan bahasa informal, sintaks tidak terstruktur, dan simbol khas media sosial (seperti emoji, <i>hashtag</i>, dan URL).</p> <p>Untuk mengoptimalkan proses analisis, penelitian ini mengevaluasi berbagai metode pra-pemrosesan <i>tweet</i> menggunakan model klasifikasi mutakhir BERT.</p> <p>Eksperimen dilakukan pada dataset dalam dua bahasa (Inggris dan Italia) untuk menguji pengaruh pra-pemrosesan terhadap akurasi analisis sentimen serta ketergantungannya pada bahasa</p>	<p>penghilangan noise dari URL/mention dan pemanfaatan emoji/hashtag) secara signifikan meningkatkan performa analisis sentimen.</p> <p>Model BERT yang dioptimalkan dengan pra-pemrosesan yang sesuai mampu mencapai kinerja terbaik dalam kedua bahasa, sekaligus mengonfirmasi bahwa pendekatan ini dapat menjadi standar baru untuk analisis sentimen teks media sosial.</p> <p>Temuan ini juga menyoroti perlunya adaptasi teknik pra-pemrosesan berdasarkan karakteristik bahasa</p>
<p>Jazuli (2023) [46]</p>	<p>Penelitian ini bertujuan untuk menganalisis sentimen mahasiswa secara lebih mendalam terhadap proses pembelajaran di sebuah universitas swasta di Indonesia dengan menggunakan pendekatan <i>Aspect-Based Sentiment Analysis</i> (ABSA).</p> <p>ABSA memungkinkan identifikasi aspek spesifik dalam ulasan serta klasifikasi sentimen terkait, yang tidak dapat dilakukan oleh metode analisis sentimen tradisional.</p> <p>Untuk mengatasi ketidakkonsistenan dalam deteksi aspek dan klasifikasi sentimen,</p>	<p>Hasil eksperimen menunjukkan bahwa:</p> <ul style="list-style-type: none"> • Model ekstraksi aspek mencapai akurasi 0.890 dan <i>F1-Score</i> 0.897. • Model klasifikasi sentimen mencapai akurasi 0.879 dan <i>F1-Score</i> 0.882. <p>Indo-BERT terbukti lebih efektif dibandingkan algoritma pembandingan (<i>Naive Bayes</i>, <i>K-NN</i>, <i>Decision Tree</i>) dalam mengidentifikasi aspek dan sentimen dalam ulasan mahasiswa.</p> <p>Temuan ini tidak hanya memvalidasi keunggulan Indo-</p>

	<p>penelitian ini mengusulkan penggunaan model Indo-BERT (model NLP terbaik untuk bahasa Indonesia) dengan penyetelan hiperparameter untuk hasil yang optimal.</p> <p>Sebagai pembanding, juga digunakan algoritma klasik seperti <i>Naive Bayes</i>, <i>K-NN</i>, dan <i>Decision Tree</i>.</p> <p>Dataset terdiri dari 10.000 ulasan mahasiswa yang dikumpulkan melalui kuesioner online</p>	<p>BERT untuk teks bahasa Indonesia, tetapi juga menyediakan dasar perbandingan kinerja antar algoritma untuk tugas ABSA.</p> <p>Penelitian ini berkontribusi pada pengembangan sistem analisis ulasan yang lebih presisi di konteks pendidikan tinggi.</p>
<p>Prattasha (2022) [47]</p>	<p>Penelitian ini mengatasi tantangan analisis sentimen dalam bahasa Bangla dengan memanfaatkan transfer learning dari model BERT yang digabungkan dengan arsitektur CNN-BiLSTM untuk meningkatkan akurasi klasifikasi.</p> <p>Tantangan utama adalah kelangkaan data berlabel standar dalam NLP bahasa Bangla, di mana penelitian sebelumnya masih bergantung pada word embeddings konteks-independen seperti <i>Word2Vec</i>, <i>GloVe</i>, dan <i>fastText</i>.</p> <p>Penelitian ini membandingkan kinerja pendekatan berbasis BERT dengan <i>embeddings</i> tradisional dan algoritma <i>machine learning</i> klasik (seperti SVM, <i>Naive Bayes</i>)</p>	<p>Hasil eksperimen menunjukkan bahwa:</p> <ul style="list-style-type: none"> • Model CNN-BiLSTM dengan BERT mencapai kinerja terbaik (<i>state-of-the-art</i>) dalam klasifikasi sentimen biner bahasa Bangla, mengungguli semua <i>embeddings</i> tradisional (<i>Word2Vec</i>, <i>GloVe</i>, <i>fastText</i>) dan algoritma klasik. • <i>Transfer learning</i> BERT secara signifikan meningkatkan akurasi dibandingkan pendekatan konteks-independen, karena kemampuannya menangkap makna kata berbasis konteks. • Perbandingan dengan algoritma klasik (seperti SVM) mengonfirmasi keunggulan arsitektur <i>hibrid</i> CNN-BiLSTM

	<p>untuk tugas klasifikasi sentimen biner.</p> <p>Dataset yang digunakan mencakup berbagai sumber teks Bangla untuk mengevaluasi generalisasi model</p>	<p>dalam mengekstrak fitur semantik dan sequential dari teks.</p> <p>Temuan ini tidak hanya memperkaya sumber daya NLP bahasa Bangla, tetapi juga membuktikan efektivitas BERT dan arsitektur <i>deep learning</i> terintegrasi untuk bahasa dengan sumber daya terbatas. Penelitian ini memberikan kerangka kerja yang dapat diadaptasi untuk bahasa <i>low-resource</i> lainnya.</p>
--	---	--

Meskipun berbagai penelitian sebelumnya telah menunjukkan keberhasilan pendekatan *machine learning* dan *deep learning* dalam klasifikasi sentimen, masih terdapat sejumlah keterbatasan dan celah yang belum terjawab secara tuntas, khususnya dalam konteks penggunaan model berbahasa Indonesia dan efisiensi proses komputasi:

1. Keterbatasan pada Studi yang Menggunakan Data Lokal (Bahasa Indonesia)

Beberapa penelitian seperti oleh Pikir et al. (2021) dan Jazuli (2023) telah menerapkan analisis sentimen dalam konteks pelayanan publik dan pendidikan di Indonesia. Namun, sebagian besar masih menggunakan pendekatan klasik seperti *Naive Bayes* atau menggunakan IndoBERT hanya untuk *fine-tuning*, tanpa mengeksplorasi secara mendalam pendekatan *transfer learning* berbasis *feature extraction* yang lebih ringan secara komputasi.

2. Kesenjangan dalam Evaluasi Efisiensi Waktu Proses

Studi seperti oleh Nugroho et al. (2021) dan Saravanan et al. (2022) memang membandingkan efisiensi waktu antara BERT dan algoritma klasik seperti *Random Forest*. Namun, penelitian tersebut belum mengkaji bagaimana *trade-off* antara akurasi dan waktu proses dapat dioptimalkan melalui strategi transfer learning yang tidak bergantung pada *fine-tuning*, yang notabene lebih berat secara sumber daya.

3. Kurangnya Fokus pada Analisis Sentimen Layanan Publik di Indonesia

Sebagian besar studi terdahulu (misalnya oleh Alqaryouti et al. (2024) dan Prottasha (2022)) masih berfokus pada sektor kesehatan atau data global/multibahasa. Meskipun

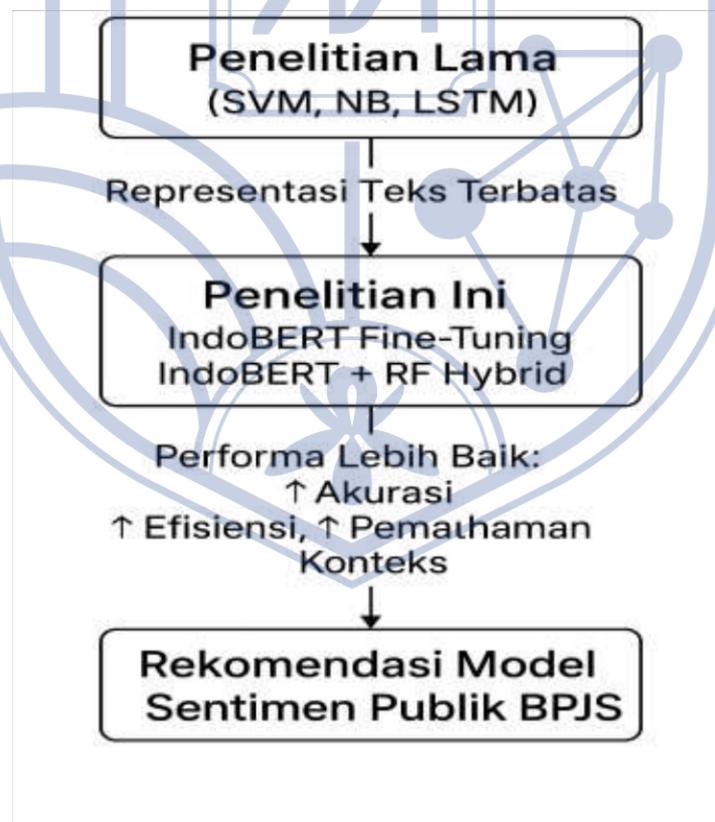
terdapat studi lokal, konteks analisis terhadap BPJS sebagai institusi layanan publik nasional masih minim dijelajahi, terutama dengan pendekatan berbasis *transformer* lokal (IndoBERT).

4. Perluasan dan Adaptasi *Transfer Learning* pada Konteks Teks Sosial Indonesia

Beberapa penelitian seperti oleh Qasim et al. (2022) dan Pota et al. (2021) menekankan efektivitas *transfer learning* dalam menangani konten media sosial yang tidak terstruktur. Namun, belum banyak studi yang menerapkannya secara kontekstual pada ulasan publik Indonesia di platform seperti *Twitter*, *TikTok*, atau *Instagram* terkait BPJS, yang notabene memiliki karakter informal dan lokal.

2.3 Kerangka Konseptual

Kerangka konseptual dalam penelitian ini dirancang untuk menunjukkan perbandingan antara pendekatan-pendekatan terdahulu dalam analisis sentimen dengan pendekatan yang diusulkan dalam penelitian ini, serta menjelaskan bagaimana penelitian ini memberikan kontribusi berupa peningkatan performa dan efisiensi. Gambar 2.3 menunjukkan ilustrasi kerangka konseptual pada penelitian ini:



Gambar 2. 3 Kerangka Konseptual

Pada pendekatan sebelumnya, analisis sentimen terhadap teks berbahasa Indonesia umumnya menggunakan metode berbasis representasi teks konvensional seperti TF-IDF atau *Bag of Words* yang dipadukan dengan algoritma klasik seperti *Support Vector Machine* (SVM), *Naive Bayes* (NB), dan model *Recurrent Neural Network* seperti LSTM. Meskipun metode tersebut cukup efektif, mereka memiliki keterbatasan dalam menangkap konteks makna kata dalam kalimat, khususnya dalam bahasa yang kaya morfologi dan konteks seperti Bahasa Indonesia.

Penelitian ini mengusulkan dua pendekatan berbasis model transformer yang mampu memahami konteks secara lebih mendalam:

1. *Fine-tuning* IndoBERT secara *end-to-end* untuk klasifikasi sentimen.
2. Pendekatan hybrid yang menggabungkan IndoBERT sebagai *feature extractor* dan algoritma *Random Forest* sebagai *classifier*.

Kedua pendekatan ini dirancang untuk mengatasi keterbatasan representasi sebelumnya dengan memanfaatkan kemampuan *contextual embedding* dari IndoBERT. Dengan demikian, fitur-fitur semantik dan sintaktik dalam komentar dapat ditangkap secara lebih efektif.

Hasil yang diharapkan dari pendekatan ini mencakup:

1. Peningkatan akurasi klasifikasi, karena model mampu memahami konteks secara lebih baik.
2. Efisiensi waktu komputasi, khususnya pada pendekatan *hybrid*.
3. Rekomendasi pemilihan model yang tepat untuk implementasi praktis analisis sentimen layanan publik (dalam hal ini BPJS Kesehatan).

Dengan demikian, kontribusi utama dari penelitian ini adalah menunjukkan bahwa pemanfaatan model berbasis *transformer* (IndoBERT), baik secara langsung maupun sebagai *feature extractor*, memberikan peningkatan performa yang signifikan dibanding pendekatan-pendekatan sebelumnya.

Tabel 2.1 menyajikan perbandingan konseptual antara pendekatan yang umum digunakan dalam penelitian terdahulu dan pendekatan yang diusulkan dalam penelitian ini. Perbandingan ini bertujuan untuk menekankan kontribusi baru yang ditawarkan dalam hal representasi bahasa, arsitektur model, serta evaluasi performa.

Tabel 2. 2 Perbandingan Konseptual

Aspek Perbandingan	Penelitian Sebelumnya	Penelitian Ini
Representasi Teks	TF-IDF, Word2Vec	Embedding kontekstual IndoBERT
Arsitektur Model	<i>Naive Bayes</i> , SVM, LSTM	IndoBERT (<i>fine-tuned</i>) dan <i>Hybrid</i> IndoBERT + RF
Spesifikasi Bahasa	Model umum (bahasa Inggris atau generik)	<i>Pretrained</i> untuk Bahasa Indonesia
Ekstraksi Fitur	Manual atau terbatas	Otomatis oleh <i>pretrained transformer</i>
Metrik Evaluasi	Akurasi	Akurasi, <i>Precision</i> , <i>Recall</i> , dan Waktu Komputasi
Aplikasi Kasus	Umum (<i>Twitter</i> , <i>review produk</i> , dll.)	Layanan publik: Komentar masyarakat tentang BPJS

