

BAB II

TINJAUAN PUSTAKA

2.1. Studi Sebelumnya

Analisis terhadap ulasan pengguna telah menjadi bidang penelitian yang esensial untuk memahami persepsi dan sentimen pemain terhadap *game*. Platform distribusi digital seperti Steam dan Google Play Store menyediakan data tekstual dalam volume besar yang dapat dianalisis untuk mengekstrak wawasan berharga. Penelitian di bidang ini telah berkembang pesat, beralih dari metode *machine learning* klasik menuju penerapan model *deep learning* yang lebih canggih untuk menangkap nuansa dan konteks dalam ulasan pemain.

Dalam konteks nasional, penelitian mengenai game dengan sistem *gacha* mulai mendapatkan perhatian signifikan antara tahun 2020-2025, seiring dengan popularitas *game* seperti Genshin Impact. Cokki et al. dalam jurnalnya *Gacha Addiction and In-App Purchases* meneliti hubungan kausal antara kecanduan *gacha* dan niat pembelian dalam *game* Genshin Impact di Indonesia. Menggunakan metode statistik PLS-SEM terhadap 208 responden. Penelitian ini menemukan bahwa kecanduan *gacha* memiliki pengaruh signifikan terhadap loyalitas dan niat beli pemain, yang secara parsial dimediasi oleh persepsi harga[4]. Temuan ini sangat relevan karena menyoroti aspek psikologis yang menjadi dasar sentimen pemain yaitu mekanisme *gacha* memicu respons emosional yang kuat yang sering kali bertentangan dengan rasionalitas ekonomi sehingga menciptakan sentimen yang kompleks dalam ulasan.

Sejalan dengan itu, Wicaksono et al. membahas strategi pengembang *game gacha* dalam memengaruhi pengeluaran pemain dari kalangan mahasiswa di Indonesia. Penelitian kualitatif ini mengungkapkan bahwa desain *gacha* secara sengaja memanfaatkan urgensi (*scarcity*), batas waktu (*limited banners*) dan elemen perjudian untuk mendorong transaksi impulsif[11]. Studi ini mendukung premis penelitian ini bahwa analisis sentimen pada *game gacha* harus memisahkan aspek monetisasi dari aspek *gameplay* karena monetisasi sering kali menjadi sumber utama keluhan etis meskipun kualitas permainan itu sendiri dinilai baik. Lebih lanjut, Bakrie et al. meneliti

determinan penggunaan berkelanjutan pada *game RPG gacha* di kalangan Gen Z dan Milenial Indonesia, menemukan bahwa Nilai Persepsi (*Perceived Value*) adalah faktor kunci yang sering kali terganggu oleh sistem monetisasi yang agresif[12].

Terkait metode analisis sentimen, Ibrahim et al. melakukan analisis sentimen pada ulasan aplikasi Astro menggunakan model BERT dan menemukan bahwa model *Transformer* ini memberikan tingkat akurasi yang sangat baik dalam menangkap konteks kalimat, jauh melampaui metode berbasis leksikon[13]. Dalam domain *game*, Fadhlurrahman dkk. membandingkan model BERT, BiLSTM, dan CRF untuk klasifikasi sentimen ulasan game di platform Steam. Mereka menemukan bahwa BERT memiliki akurasi lebih tinggi dibandingkan CRF, namun mencatat bahwa model LSTM memiliki keunggulan komparatif dalam menangkap konteks pada kalimat yang sangat panjang dan berbelit-belit[14]. Temuan ini menjadi dasar pemilihan model berbasis *Transformer* (RoBERTa) dalam penelitian ini, yang merupakan pengembangan lebih lanjut dari BERT untuk mengatasi kelemahan-kelemahan tersebut.

Perbandingan spesifik antara kinerja model Transformer dilakukan oleh Rafiandi et al. dan peneliti lain dalam jurnal-jurnal terbaru. Sebuah studi berjudul "Perbandingan IndoBERT dan IndoRoBERTa Untuk Analisis Sentimen" mengevaluasi kedua model pada ulasan film dokumenter. Hasilnya menunjukkan bahwa dalam beberapa kasus dataset bahasa Indonesia spesifik, IndoBERT mencapai akurasi lebih tinggi (99%) dibandingkan IndoRoBERTa (94%) karena pra-pelatihan yang lebih terfokus pada korpus lokal[15]. Namun, penelitian lain oleh Sirusstara et al. dan Tan KL et al. menunjukkan keunggulan arsitektur RoBERTa (terutama versi multilingual atau bahasa Inggris) dalam mendeteksi nuansa bahasa yang lebih halus, sarkasme, dan konteks implisit pada dataset standar internasional seperti Twitter US Airline dan IMDB, di mana RoBERTa secara konsisten mengungguli BERT standar[16]. Hal ini mengindikasikan bahwa RoBERTa memiliki potensi besar untuk menangani kompleksitas linguistik ulasan game yang sering mencampurkan bahasa Inggris dan Indonesia.

Dalam ranah Aspect-Based Sentiment Analysis (ABSA), Aryanti et al. menerapkan ABSA menggunakan kombinasi LDA (*Latent Dirichlet Allocation*) untuk ekstraksi topik

dan IndoBERT untuk klasifikasi sentimen pada aplikasi kesehatan mental Riliv. Studi ini berhasil mengidentifikasi sentimen spesifik pada aspek Antarmuka Pengguna dan Layanan Konseling, membuktikan bahwa pendekatan berbasis aspek memberikan wawasan yang jauh lebih kaya dan terarah daripada analisis sentimen umum[17]. Penelitian serupa pada *e-commerce* oleh peneliti lain menggunakan LSTM dan CNN juga menunjukkan efektivitas ABSA dalam memisahkan opini tentang pengiriman, harga, dan kualitas produk, meskipun akurasi masih di bawah model berbasis *Transformer*[18]. Wafda juga menerapkan ABSA dengan IndoBERT pada cuitan tentang Kurikulum Merdeka mencapai *F1-score* 86% untuk klasifikasi sentimen aspek, menegaskan kematangan metode ini untuk analisis opini publik[19].

Tidak ada penelitian yang ditemukan yang secara spesifik menganalisis persimpangan dari kedua dunia ini. Sentimen dari pemain game PC premium dalam hal ini pemain Destiny 2 terhadap pengenalan model monetisasi *free-to-play gacha* seperti Destiny: Rising dalam *franchise* yang sama.

Pemain Destiny 2 terbiasa dengan model ekonomi premium dan *live service* yaitu ekspansi berbayar dan *season pass*, yang menciptakan ekspektasi ekonomi berbasis kepastian yaitu membayar sejumlah uang untuk mendapatkan sejumlah konten yang dijamin. Di sisi lain, model *gacha free-to-play* pada Destiny: Rising memperkenalkan ekonomi berbasis peluang yaitu membayar sejumlah uang untuk mendapatkan kesempatan memperoleh konten.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut. Dengan menerapkan metodologi ABSA yang tervalidasi pada ulasan dari pemain Destiny 2, penelitian ini akan secara *fine-grained* menganalisis sentimen mereka terhadap aspek-aspek spesifik dari model *gacha* (misalnya *pity system*, *banner*, *pull rates*). Hipotesisnya adalah bahwa sentimen pemain premium terhadap aspek monetisasi akan secara fundamental berbeda (cenderung lebih negatif) dibandingkan dengan sentimen pemain *gacha* yang mungkin berasal dari benturan ekspektasi dan budaya monetisasi yang telah terbangun.

Berdasarkan tinjauan di atas, terdapat kesenjangan penelitian (*research gap*) yang jelas. Meskipun banyak studi membahas *gacha* dari sisi psikologis dan ekonomi, banyak

studi menerapkan BERT/RobERTa untuk analisis sentimen umum. Namun, belum banyak penelitian nasional yang secara spesifik menerapkan ABSA dengan model RoBERTa untuk mengevaluasi transisi sistem monetisasi pada sebuah *franchise game* besar (Destiny) yang baru saja merilis versi mobile berbasis *gacha*. Kebanyakan penelitian *game* masih menggunakan metode klasifikasi tradisional (Naïve Bayes, SVM) atau BERT standar dan jarang yang membedah dampak spesifik perubahan model bisnis terhadap sentimen komunitas veteran vs baru. Penelitian ini bertujuan mengisi celah tersebut dengan menggabungkan analisis teknis NLP mutakhir dengan konteks industri game yang sangat spesifik.

Untuk memposisikan penelitian ini, Tabel 2.1 menyajikan perbandingan antara studi-studi sebelumnya yang relevan dengan penelitian yang diusulkan.

No	Penulis	Tahun	Objek Penelitian	Metode	Hasil
1	Cokki et al.[4]	2025	Adiksi <i>gacha</i> pada niat beli pemain terhadap <i>game</i> Genshin Impact	PLS-SEM (Kuantitatif)	Adiksi <i>gacha</i> secara signifikan memengaruhi niat beli dan loyalitas memediasi hubungan tersebut. <i>Gacha</i> memicu perilaku impulsive.
2	Wicaksono et al.[11]	2024	Strategi Pengembang pada <i>Game Gacha</i>	Analisis Kualitatif	Desain <i>gacha</i> menggunakan urgensi, kelangkaan, dan pola lotere untuk memaksimalkan pendapatan dari pemain.
3	Fadhlurrahman et al.[15]	2023	Sentimen Ulasan <i>Game</i> Steam	BERT, BiLSTM, CRF	BERT memberikan akurasi lebih tinggi dari CRF. Ulasan negatif <i>game</i> cenderung lebih panjang dan mendalam.

No	Penulis	Tahun	Objek Penelitian	Metode	Hasil
4	Aryanti et al.[17]	2025	ABSA Aplikasi Kesehatan Mental (Riliv)	IndoBERT + LDA	ABSA efektif memisahkan sentimen fitur (UI vs Layanan). IndoBERT unggul dalam ekstraksi fitur dibanding baseline.
5	Rahman & Sibaroni[14]	2025	Sentimen pemain pada <i>game</i> Mobile Legends	Hybrid CNN-LSTM	Model <i>Hybrid</i> dengan optimasi fitur mencapai akurasi 88.84% pada ulasan <i>game</i> berbahasa Indonesia.
6	Tan KL et al.[16]	2023	Komparasi Kinerja BERT dan RoBERTa	Transformer Models	RoBERTa secara konsisten mengungguli BERT pada dataset sentimen standar karena optimasi pra-pelatihan dan <i>dynamic masking</i> .
7	Wafda[19]	2025	ABSA Opini Publik pada Kurikulum Merdeka	IndoBERT Fine-Tuning	Model ABSA dengan IndoBERT mencapai presisi aspek 99% dan sentimen 86% membuktikan kehandalan <i>Transformer</i> untuk ABSA.
8	Penelitian oleh penulis	2025	Menganalisis sentimen terhadap sistem monetisasi <i>free-to-play</i> berbasis <i>Gacha</i> pada Destiny: Rising.	ABSA (RoBERTa)	Fokus spesifik pada perbedaan model Premium vs <i>Gacha</i> menggunakan ABSA (RoBERTa) pada data Reddit.

Tabel 2. 1 Penelitian Terdahulu

2.2. Dasar Teori

2.2.1 Model Monetisasi Video Game

Landasan teoretis ini krusial untuk memahami konteks domain penelitian, karena fokus utama skripsi ini adalah sentimen terhadap pergeseran model monetisasi.

1. Model Premium dan *Live Service*

Model premium atau *pay-to-play*, adalah model monetisasi tradisional di mana pemain melakukan satu kali pembayaran di muka untuk mendapatkan akses penuh ke konten inti *game*.

Seiring perkembangan industri, model ini berevolusi menjadi model *live service* premium, yang menjadi konteks utama bagi pemain Destiny 2. Model ini menggabungkan pembelian awal dengan penjualan konten pasca-rilis yang berkelanjutan untuk menghasilkan pendapatan jangka panjang[20]. Bentuk monetisasi dalam model *live service* premium meliputi:

- **Expansions** – Paket konten besar yang dijual secara terpisah seperti ekspansi "The Edge of Fate" seharga \$40 dalam Destiny 2.
- **Season Pass** – Sistem *battle pass* berbayar yang memberikan hadiah dalam game seiring kemajuan pemain selama satu musim konten.
- **Downloadable Content (DLC)** – Penjualan item atau akses spesifik, seperti *Dungeon Keys* di Destiny 2 yang dijual seharga \$20.

Implikasi psikologis utama dari model ini adalah terciptanya ekspektasi pemain yang berbasis pada transaksi pasti (ekonomi kepastian). Pemain membayar sejumlah uang X untuk mendapatkan sejumlah konten Y yang dijamin.

2. Model *Free-to-Play* (F2P)

Model *free-to-play* (F2P) adalah model bisnis yang menghilangkan hambatan masuk secara finansial sehingga pemain dapat mengunduh dan memainkan game secara gratis. Pendapatan dihasilkan setelah instalasi melalui transaksi mikro (*in-app purchases*). Model ini bergantung pada keterlibatan (*engagement*) jangka panjang dan konversi sebagian kecil dari basis pemain (sering disebut *whales*) untuk menjadi pembelanja utama. Transaksi mikro dalam model F2P dapat mencakup *item* utilitas, *item* kosmetik (kustomisasi visual), atau *battle pass*[4].

3. Mekanisme *Gacha*

Mekanisme *gacha* adalah sub-kategori spesifik dari monetisasi F2P yang menjadi fokus utama penelitian ini.

- **Definisi dan Asal:** Istilah ini berasal dari mesin mainan kapsul "Gachapon" di Jepang. Mekanisme intinya adalah pemain membelanjakan mata uang (baik mata uang virtual yang diperoleh gratis atau mata uang premium yang dibeli dengan uang nyata) untuk menerima *item* virtual secara acak.
- **Perbedaan Fundamental:** Berbeda dengan pembelian langsung (misalnya membeli *skin* di Mobile Legends), *gacha* adalah pembelian peluang atau kesempatan, bukan pembelian *item* yang pasti. Model ini sering dikritik karena kemiripannya dengan perjudian[3].
- **Terminologi Kunci (Target Aspek):** Untuk melakukan ABSA pada ulasan *gacha*, pemahaman terminologi yang digunakan pemain sangat penting. Istilah-istilah ini kemungkinan akan menjadi target ekstraksi aspek (ATE):
 - **Pull / Wish / Draw:** Merujuk pada satu kali tindakan menukar mata uang untuk mendapatkan satu hadiah acak.
 - **Banner:** Merujuk pada *pool* hadiah spesifik yang tersedia untuk ditarik. *Banner* sangat penting secara strategis karena seringkali dibagi menjadi *Standard Banner* (permanen) dan *Limited-Time Banner* (terbatas) yang menampilkan karakter atau item eksklusif. *Banner* terbatas ini menciptakan insentif psikologis *Fear of Missing Out* (FOMO)
 - **Rarity:** Sistem probabilitas di mana item yang paling diinginkan (misalnya karakter "Bintang 5") memiliki tingkat kemungkinan *drop* yang sangat rendah.
 - **Pity System:** Sebuah mekanisme jaminan. Jika seorang pemain melakukan sejumlah *pull* (misalnya 89 kali) pada satu *banner* tanpa mendapatkan *item* dengan kelangkaan tertinggi, *pull* berikutnya (misalnya yang ke-90) dijamin akan menghasilkan *item* tersebut. Ini adalah aspek penting yang sering dibahas pemain terkait "keadilan" sistem.

Dalam kasus *Destiny: Rising*, terjadi pergeseran fundamental ke model *Hero Collection* berbasis *gacha*. Jika di *Destiny 2* pemain membuat karakter sendiri (*Guardian*) dan memilih kelas (*Titan/Warlock/Hunter*) secara gratis. Di *Destiny: Rising* pemain harus mendapatkan karakter-karakter tertentu (disebut *Lightbearers*) melalui sistem *gacha*. Karakter dengan tingkat kelangkaan (*rarity*) tinggi (misalnya bintang 5) memiliki statistik dan kemampuan yang jauh lebih kuat, namun probabilitas mendapatkannya sangat kecil (sering di bawah 1%)[5]. Hal ini menciptakan persepsi P2W di mana pemain yang menghabiskan uang memiliki keunggulan kompetitif yang signifikan. Selain itu, *game* ini mengadopsi sistem stamina yang membatasi jumlah aktivitas yang bisa dilakukan per hari, mendorong pembelian item penyegar stamina, sebuah praktik yang sangat umum di *game mobile* namun sering kali ditolak oleh komunitas *gamer* PC maupun Konsol.

2.2.2 Natural Language Processing (NLP)

Natural Language Processing (NLP) adalah cabang dari ilmu komputer, kecerdasan buatan, dan linguistik yang berfokus pada interaksi antara komputer dan bahasa manusia (bahasa alami). Tujuan utama NLP adalah untuk memproses, menganalisis, dan memahami data tekstual dalam volume besar untuk mengekstrak makna, wawasan, dan informasi yang terkandung di dalamnya. Dalam konteks penelitian ini, NLP berfungsi sebagai payung metodologis, di mana analisis sentimen dan ABSA merupakan salah satu aplikasi utamanya untuk mengubah data ulasan pemain yang tidak terstruktur menjadi wawasan sentimen yang terstruktur[21].

Dalam konteks analisis ulasan game di platform seperti Reddit, NLP berfungsi sebagai jembatan untuk mengubah data mentah yang penuh dengan ambiguitas, bahasa gaul (*slang*), singkatan, dan nuansa sarkasme menjadi data terstruktur yang dapat dianalisis secara kuantitatif. Tantangan utama NLP dalam domain ini adalah menangkap makna kontekstual yang seringkali implisit, di mana satu kata bisa memiliki makna berbeda tergantung konteks kalimatnya (misalnya kata "*sick*" bisa berarti buruk atau sangat keren dalam *gaming slang*).

2.2.3 Analisis Sentimen

Analisis sentimen atau yang dikenal juga sebagai *opinion mining* adalah proses mengidentifikasi, memahami dan mengklasifikasikan opini, emosi, atau sentimen yang diekspresikan dalam data teks[22]. Tujuan utamanya adalah untuk menentukan

polaritas sentimen, apakah bersifat positif, negatif, atau netral terhadap suatu topik, produk, layanan, atau entitas tertentu. Secara umum, analisis sentimen dapat dikelompokkan ke dalam tiga kategori utama:

1. **Analisis Sentimen Polaritas** – Menentukan apakah sentimen suatu teks bersifat positif, negatif, atau netral.
2. **Analisis Sentimen Berbasis Emosi** – Mengidentifikasi jenis emosi tertentu dalam teks, seperti marah, bahagia, sedih, atau takut[23].
3. **Analisis Sentimen Aspek-Sentris** – Menganalisis sentimen yang berhubungan dengan aspek tertentu dari suatu entitas[24].

Teknik dalam analisis sentimen dapat dibagi menjadi beberapa pendekatan utama:

1. Pendekatan Berbasis Kamus (*Lexicon-Based Approach*)

Pendekatan ini menggunakan daftar kata yang telah dikategorikan berdasarkan sentimen (positif atau negatif). Beberapa contoh kamus yang sering digunakan dalam analisis sentimen adalah SentiWordNet[25].

Kelebihan:

- Tidak memerlukan data pelatihan yang besar.
- Mudah diimplementasikan untuk berbagai bahasa.

Kekurangan:

- Tidak dapat memahami konteks atau makna kata dalam kalimat.
- Kesulitan dalam menangani ironi, sarkasme, atau kata-kata yang memiliki makna ganda.

2. Pendekatan Berbasis Pembelajaran Mesin (*Machine Learning-Based Approach*)

Metode ini menggunakan algoritma pembelajaran mesin yang dilatih pada dataset berlabel untuk mengklasifikasikan sentimen[26]. Algoritma yang umum digunakan dalam analisis sentimen berbasis pembelajaran mesin meliputi:

- **Naïve Bayes (NB)** – Algoritma probabilistik yang sering digunakan untuk klasifikasi teks[27].
- **Support Vector Machine (SVM)** – Model berbasis vektor yang mencari hiperbidang terbaik untuk memisahkan kelas sentimen[28].

- **Random Forest (RF)** – Algoritma berbasis pohon keputusan yang dapat digunakan untuk klasifikasi sentimen[29].

Kelebihan:

- Lebih akurat dibandingkan pendekatan berbasis kamus.
- Dapat menangkap pola kompleks dalam teks.

Kekurangan:

- Membutuhkan dataset pelatihan yang cukup besar.
- Performanya dapat dipengaruhi oleh kualitas fitur yang diekstraksi dari teks.

3. Pendekatan Berbasis *Deep Learning* (*Deep Learning-Based Approach*)

Dengan kemajuan dalam jaringan saraf tiruan (*Artificial Neural Networks*), metode berbasis *deep learning* semakin populer dalam analisis sentimen[30]. Beberapa model *deep learning* yang sering digunakan antara lain

- **Long Short-Term Memory (LSTM)** – Versi RNN yang lebih baik dalam menangani dependensi jangka panjang dalam teks[31].
- **Bidirectional Encoder Representations from Transformers (BERT)** – Model berbasis *Transformer* yang dapat memahami konteks kata dalam kalimat lebih baik dibandingkan model lain[32].

2.2.4 *Aspect-Based Sentiment Analysis* (ABSA)

Analisis sentimen standar tidak memadai untuk penelitian ini. Sebuah ulasan seperti "*Gameplay* Destiny: Rising sangat seru dan mengingatkan pada Destiny 2, tetapi sistem *gacha*-nya adalah perampokan predator dan merusak pengalaman", akan diklasifikasikan secara keliru sebagai Netral oleh model standar.

Aspect-Based Sentiment Analysis (ABSA) didefinisikan sebagai pendekatan analisis sentimen *fine-grained* yang bertujuan untuk mengidentifikasi sentimen terhadap aspek (fitur atau atribut) spesifik dari suatu entitas. Dengan ABSA, contoh ulasan di atas dapat diekstraksi secara akurat[33].

Secara konseptual, ABSA terdiri dari dua subtask utama yaitu:

- **Aspect Term Extraction (ATE)**: Tugas ini mengekstraksi istilah-istilah aspek yang eksplisit disebutkan dalam teks[34]. Dalam konteks penelitian ini, ATE akan dilatih untuk mengidentifikasi entitas seperti "*gacha*",


"monetisasi", "pull rate", "pity", serta aspek game lainnya seperti "gameplay", "grafik", dan "cerita".

- **Aspect Sentiment Classification (ASC):** Tugas ini menentukan polaritas sentimen (positif, negatif, atau netral) untuk setiap aspek yang telah diekstraksi pada sub tugas ATE[35].

Penelitian ini akan menggunakan ABSA untuk membedah sentimen pemain, mengisolasi opini mereka tentang aspek-aspek monetisasi *gacha* dan membandingkannya dengan opini mereka tentang aspek-aspek inti gameplay.

2.2.5 BERT (*Bidirectional Encoder Representations from Transformers*)

BERT (*Bidirectional Encoder Representations from Transformers*) adalah model bahasa canggih yang memahami konteks kata secara bidireksional, mengatasi batasan model sebelumnya yang sekuensial. Metode ini beroperasi dalam dua fase: pra-pelatihan pada korpus teks besar dengan tugas *Masked Language Model* (MLM) untuk memprediksi kata tertutup dan *Next Sentence Prediction* (NSP) untuk memahami hubungan antar kalimat, yang menghasilkan model dengan representasi semantik kata yang kaya. Selanjutnya, model BERT yang sudah terlatih disesuaikan (*fine-tuned*) untuk tugas-tugas NLP spesifik seperti klasifikasi teks atau penjawaban pertanyaan, dengan menambahkan lapisan output kecil dan melatihnya dengan data berlabel yang lebih sedikit[36].



Gambar 2. 1 Arsitektur BERT

Proses pelatihan BERT diawali dengan tahap pre-training, di mana model dilatih menggunakan kumpulan teks berskala besar untuk menyelesaikan dua tugas utama, yaitu *Masked Language Model* (MLM) yang bertujuan memprediksi kata-kata yang disembunyikan dalam kalimat, dan *Next Sentence Prediction* (NSP) yang berfungsi

menentukan hubungan antar kalimat. Tahap ini memungkinkan BERT membangun representasi bahasa yang kontekstual dan mendalam. Setelah *pre-training*, model BERT dapat disesuaikan melalui proses *fine-tuning*, yaitu penyesuaian parameter pada lapisan-lapisan atas model terhadap dataset spesifik suatu tugas seperti klasifikasi teks, *Named Entity Recognition* (NER), atau *Question Answering* (QA)[36]. Arsitektur BERT sendiri dibangun di atas komponen utama Transformer, yaitu mekanisme *self-attention* yang memungkinkan pemodelan hubungan antar kata secara paralel, *feed-forward layers* yang berperan memperkuat fitur representasi, serta *positional encoding* yang memberikan informasi posisi kata dalam kalimat mengingat Transformer tidak memproses data secara sekuensial seperti RNN. Pendekatan ini menjadikan BERT sebagai fondasi kuat untuk pengembangan berbagai aplikasi NLP yang presisi dan adaptif.

Seiring dengan perkembangannya, BERT mengalami berbagai adaptasi dan pengembangan lanjutan yang bertujuan untuk meningkatkan performa, efisiensi, maupun kesesuaian dengan kebutuhan tertentu. Beberapa varian BERT yang umum digunakan dalam penelitian NLP dijelaskan sebagai berikut.

1. **RoBERTa** merupakan pengembangan dari BERT yang diperkenalkan oleh Facebook AI. Model ini mempertahankan arsitektur dasar BERT tetapi melakukan optimalisasi pada proses *pre-training*. Beberapa perbedaan utama RoBERTa dibandingkan BERT asli adalah penggunaan *dataset* yang lebih besar, penghapusan tugas *Next Sentence Prediction*, serta penerapan *dynamic masking*. Optimalisasi tersebut membuat RoBERTa mampu menghasilkan representasi bahasa yang lebih kuat dan stabil[37]. Dalam konteks penelitian ini, RoBERTa dipilih karena terbukti memberikan performa yang lebih baik dalam tugas analisis sentimen, khususnya pada data teks informal seperti komentar pengguna di media sosial dan forum daring.
2. **DistilBERT** merupakan versi ringan dari BERT yang dikembangkan melalui teknik *knowledge distillation*. Model ini memiliki ukuran yang lebih kecil dan waktu inferensi yang lebih cepat, namun tetap mempertahankan sebagian besar kemampuan representasi bahasa dari BERT asli[38]. DistilBERT umumnya digunakan pada aplikasi yang memiliki keterbatasan

sumber daya komputasi atau membutuhkan respons yang cepat, meskipun terdapat sedikit penurunan akurasi dibandingkan BERT penuh.

3. **ALBERT** dikembangkan untuk mengatasi permasalahan besar jumlah parameter pada BERT. Model ini menerapkan teknik *parameter sharing* dan *factorized embedding* parameterization untuk mengurangi ukuran model secara signifikan. Dengan pendekatan tersebut, ALBERT mampu meningkatkan efisiensi memori dan kecepatan pelatihan, serta tetap mempertahankan performa yang kompetitif pada berbagai tugas NLP[39].
4. **Multilingual BERT** atau mBERT merupakan varian BERT yang dilatih menggunakan data dari berbagai bahasa secara simultan. Model ini memungkinkan penerapan NLP lintas bahasa tanpa perlu melatih model secara terpisah untuk setiap bahasa. mBERT banyak digunakan dalam penelitian yang melibatkan teks multibahasa, meskipun performanya pada satu bahasa tertentu umumnya masih berada di bawah model yang dilatih secara khusus pada bahasa tersebut[40].

Berdasarkan berbagai varian BERT yang telah dijelaskan, pemilihan model dalam penelitian harus disesuaikan dengan karakteristik data dan tujuan analisis. Penelitian ini menggunakan RoBERTa karena model tersebut memiliki kemampuan representasi konteks yang lebih baik dan terbukti efektif dalam menangani teks informal dari media sosial[41]. Hal ini menjadikan RoBERTa relevan untuk menganalisis sentimen pemain terhadap sistem monetisasi *free-to-play* berbasis *gacha* pada game Destiny: Rising.

2.2.6 RoBERTa (A Robustly Optimized BERT Pretraining Approach)

RoBERTa adalah model yang dipilih untuk penelitian ini karena merupakan evolusi dan optimalisasi langsung dari BERT yang terbukti menghasilkan kinerja yang lebih unggul. RoBERTa bukanlah arsitektur yang sepenuhnya baru melainkan pendekatan pra-pelatihan BERT yang dioptimalkan secara kuat (*A Robustly Optimized BERT Pretraining Approach*)[42].

Dalam penelitian ini, model RoBERTa dipilih sebagai arsitektur utama untuk tugas ABSA. Keunggulan dan perbedaan teknis RoBERTa dibandingkan BERT, yang menjadi justifikasi pemilihannya untuk penelitian ini, adalah sebagai berikut:

- **Penghapusan Tugas NSP:** Peneliti RoBERTa menemukan bahwa tugas *Next Sentence Prediction* (NSP) secara signifikan mengurangi kinerja downstream. RoBERTa menghapus tugas ini dan hanya fokus pada MLM, yang terbukti lebih efektif[43].
- **Pelatihan dengan Data yang Jauh Lebih Besar:** BERT dilatih pada 16GB teks. RoBERTa dilatih pada korpus data 160GB termasuk data dari CommonCrawl, yang memberikan pemahaman bahasa yang lebih kaya, lebih beragam, dan lebih umum[43].
- **Dynamic Masking:** BERT menerapkan masking kata (untuk tugas MLM) sekali di awal dan menyimpannya secara statis selama pelatihan. Sebaliknya, RoBERTa menggunakan *dynamic masking*, di mana pola masking dibuat ulang setiap kali sebuah urutan dimasukkan ke model. Hal ini membuat model lebih tangguh dan mencegah *overfitting* pada pola *masking* tertentu[43].
- **Optimalisasi Ukuran Batch:** RoBERTa dilatih dengan ukuran batch yang jauh lebih besar, yang telah terbukti meningkatkan stabilitas pelatihan dan kinerja *fine-tuning* pada tugas-tugas *downstream*[43].

Karena optimalisasi ini, RoBERTa secara konsisten mengungguli BERT pada sebagian besar *benchmark* NLP. Dalam konteks analisis sentimen berbasis aspek pada data komentar Reddit yang bersifat informal dan kontekstual, kemampuan RoBERTa dalam memahami dependensi kata dan nuansa semantik menjadi sangat penting. Dibandingkan dengan metode lexicon-based seperti VADER yang bergantung pada kamus kata statis, RoBERTa mampu menginterpretasikan makna kalimat secara kontekstual, termasuk pada kasus ironi, ambiguitas, dan opini implisit. Oleh karena itu, RoBERTa dipilih sebagai model utama karena lebih sesuai untuk menangkap kompleksitas persepsi pemain terhadap sistem monetisasi *game*[44].

2.3. Tabel Perbandingan

Aspek	Naïve Bayes	SVM (Support Vector Machine)	BERT (Bidirectional Encoder Representations from Transformers)	RoBERTa (Robustly Optimized BERT Pretraining Approach)
Metode	Probabilistik (berbasis Teorema Bayes)	Pemisahan data berdasarkan <i>hyperplane</i> <i>optimal</i>	<i>Transformer-based</i> model dengan pemahaman kontekstual bidirectional	<i>Transformer Optimized Encoder Stack</i>
Pemahaman Konteks	Rendah (mengabaikan urutan dan konteks kata)	Sedang (bergantung pada kernel dan rekayasa fitur manual)	Tinggi (Konteks Bidirectional penuh pada level kalimat)	Sangat Tinggi (Konteks Bidirectional yang dioptimalkan dengan data 10x lebih besar)
Penanganan Sarkasme & Nuansa	Sangat Rendah	Rendah	Sedang hingga Tinggi	Tinggi (Pemahaman nuansa bahasa yang lebih baik karena dilatih pada data yang jauh lebih beragam)
Kebutuhan Data Pelatihan (<i>Fine-tuning</i>)	Kecil	Sedang	Besar	Besar (Membutuhkan sumber daya komputasi yang sangat besar untuk pra-pelatihan)
Kompleksitas Komputasi	Sangat Rendah	Sedang	Sangat Tinggi	Sangat Tinggi (Lebih intensif secara komputasi dibandingkan BERT)
Kinerja pada Tugas ABSA	Rendah	Sedang (Dapat digunakan untuk klasifikasi aspek dasar)	Tinggi (Menjadi dasar yang kuat untuk banyak penelitian ABSA)	Sangat Tinggi (Terbukti unggul dalam benchmark NLP 36 dan digunakan secara spesifik untuk ABSA)

Tabel 2. 2 Tabel Perbandingan