

Analisis Konten Trash Talking dalam Konten Game Online Mobile Legends pada Akun YouTube Jonathan Liandi menggunakan Metode KNN

Ahmad Dwi Raharjo Septiawan^{1*}, Siti Mujilahwati², Azza Abidatin Bettaliyah³

^{1,2,3} Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Lamongan, Jawa Timur, Indonesia

dwi420408@gmail.com^{1*}, moedjee@unisla.ac.id², azzabettaliyah@unisla.ac.id³

Abstrak

Fenomena *trash talking* (ujaran provokatif) dalam konten *Mobile Legends: Bang Bang* di YouTube dapat memengaruhi pola komunikasi di kalangan audiens muda, khususnya remaja. Penelitian ini bertujuan untuk menganalisis bentuk linguistik *trash talking* pada kanal Jonathan Liandi, mengembangkan pengklasifikasi otomatis untuk komentar *trash talking*, dan menguji potensi dampaknya terhadap penonton.

Korpus sebanyak 500 komentar YouTube dikumpulkan melalui *web scraping* dan diproses awal menggunakan *case folding*, *cleansing*, normalisasi, tokenisasi, penghapusan *stopword* (*stopword removal*), dan *stemming*. Fitur diekstraksi menggunakan metode Term Frequency–Inverse Document Frequency (TF–IDF) dan diklasifikasikan dengan algoritma k-Nearest Neighbor (KNN) dengan nilai $k=3$. Dataset dibagi menjadi 80% untuk pelatihan (*training*) dan 20% untuk pengujian (*testing*), serta kinerja model dievaluasi menggunakan akurasi, presisi, *recall*, dan F1–score.

Temuan mengungkapkan bahwa *trash talking* muncul dalam delapan kategori linguistik, termasuk istilah hewan, bagian tubuh, kata sifat, kata benda, kata kerja, kondisi atau keadaan, profesi atau status sosial, dan makian spontan (*spontaneous expletives*). Model KNN mencapai akurasi 85%, presisi 93,5%, *recall* 78,2%, dan F1–score 85,1%, yang menunjukkan bahwa TF–IDF yang dikombinasikan dengan KNN menyediakan garis dasar (*baseline*) yang efektif untuk mendeteksi bahasa ofensif dalam komentar terkait *game*. *Trash talking* dalam konten yang dianalisis bervariasi dan sangat terlihat di kalangan audiens.

Meskipun pendekatan komputasi ini terbukti cocok untuk deteksi tahap awal, integrasi model yang peka konteks seperti *deep learning* serta promosi literasi digital yang lebih kuat dan kebijakan pembatasan usia disarankan untuk memitigasi dampak perilaku negatif.

Kata Kunci: *Trash Talking*; *Mobile Legends*; YouTube; KNN; TF–IDF; *web scraping*

1. Pendahuluan

Perkembangan teknologi informasi dan komunikasi telah memberikan pengaruh signifikan terhadap masyarakat, terutama setelah kemunculan Internet, yang kini menjadi bagian tak terpisahkan dari kehidupan sehari-hari [1]. Kemajuan teknologi media juga memainkan peran penting dalam mentransformasi komunikasi manusia. Munculnya Media Baru (*New Media*), seperti platform media sosial YouTube, Facebook, Instagram, dan lainnya, telah memperluas eksistensi media melampaui media cetak dan siaran. Di antara banyaknya saluran komunikasi yang tersedia saat ini, Media Baru dianggap sebagai medium yang paling sering diakses dan paling berpengaruh dalam kehidupan sehari-hari [2].

Media sosial merepresentasikan terobosan besar dalam komunikasi modern, yang dimungkinkan melalui evolusi teknologi internet. Media sosial telah membawa perubahan substansial pada interaksi manusia dan pemenuhan kebutuhan sosial. Media sosial memungkinkan orang untuk berkomunikasi dengan mudah dengan orang lain, bahkan mereka yang secara geografis berjauhan [3]. Umumnya dikenal sebagai platform jejaring sosial, aplikasi media sosial melayani beragam tujuan dan audiens. Contoh populer meliputi Facebook, Twitter, YouTube, Instagram, dan Tumblr. Di antara platform ini, YouTube menonjol sebagai platform berbagi video berbasis web yang sangat populer dan berpengaruh.

YouTube saat ini menjadi salah satu platform yang paling disukai di kalangan anak-anak dan remaja. Beberapa penelitian menunjukkan bahwa YouTube dapat memberikan banyak manfaat edukatif, terutama dalam mengajarkan pengetahuan dan keterampilan baru kepada anak-anak. Namun, platform ini juga dapat menimbulkan efek negatif ketika anak-anak terpapar pada konten yang tidak pantas. Penelitian mengindikasikan bahwa YouTube memiliki dampak ganda pada perkembangan bahasa anak-anak. Di satu sisi, konten edukatif dapat meningkatkan kosakata, pemahaman bahasa asing, dan keterampilan komunikasi. Di sisi lain, paparan terhadap konten yang tidak pantas atau kata-kata kotor dapat memengaruhi pola bicara secara negatif. Oleh karena itu, pengawasan orang tua sangat penting untuk memaksimalkan manfaat dari konten positif dan meminimalkan risiko yang ditimbulkan oleh materi berbahaya [4].

Pergeseran perilaku yang umum diamati di kalangan anak-anak dan remaja saat ini adalah agresi verbal atau ucapan kasar. Fenomena ini muncul karena akses tanpa batas terhadap konten dewasa yang mengandung kekerasan verbal. Salah satu contoh populer adalah konten *game online*, khususnya dari *game Mobile Legends: Bang Bang*. *Game* ini dimainkan secara luas oleh orang-orang dari segala usia di

Indonesia, termasuk anak-anak. Dalam mencari hiburan atau mempelajari keterampilan *game* baru, penonton muda sering menonton *YouTube* yang sesuai dengan preferensi mereka tanpa mempertimbangkan kesesuaian konten. Hal ini dapat menyebabkan kekaguman atau fanatisme berlebihan, mendorong mereka untuk meniru bahasa dan perilaku *streamer* tanpa memahami konsekuensinya.

Mobile Legends adalah *game Multiplayer Online Battle Arena* (MOBA) yang telah mendapatkan popularitas besar. Menurut data dari Google Play Store, *game* ini telah diunduh lebih dari 100 juta kali dan menempati peringkat ketiga di antara *game* paling populer. Daya tariknya terletak pada *gameplay* yang menarik, kontrol bergaya *joystick* yang intuitif, berbagai tombol *skill*, dan fitur cerdas yang cocok untuk pemula maupun profesional. *Game* ini juga menawarkan berbagai pilihan *hero* dan *skin* yang dapat disesuaikan. Pemain dapat membentuk tim untuk menyusun strategi dan mengalahkan lawan, menciptakan lingkungan yang sangat interaktif dan kompetitif.

Trash talking adalah bagian dari perilaku toksik dalam *gaming*. Menurut [5], tidak ada definisi standar tentang "toksik," tetapi secara umum dipahami sebagai perilaku yang sengaja mengganggu atau merusak kenyamanan orang lain. Istilah "toksik" sendiri berarti "beracun," dan dalam konteks *gaming*, mengacu pada pemain yang sengaja mengganggu *gameplay*, merugikan rekan satu tim, atau melakukan pelecehan verbal terhadap orang lain. Dalam konteks ini, agresi verbal seperti *trash talking* menjadi semakin lazim. Aruguete et al. (2022) menyatakan bahwa "perkembangan pesat *game multiplayer online* telah membuka jalan baru bagi perilaku agresif seperti komunikasi yang bermusuhan, sabotase, dan *griefing*" [6]. Contoh perilaku toksik termasuk meninggalkan *keyboard* (AFK), *feeding*, pemilihan *hero* secara acak, *kill stealing*, kurangnya kerja sama, dan penggunaan kata-kata kotor atau *trash talking*. Pemain yang terlibat dalam perilaku ini dikategorikan sebagai pengguna toksik, karena tindakan tersebut dapat mengganggu kesenangan dan kenyamanan orang lain.

Isu toksisitas dalam *gaming* telah mendapatkan perhatian lebih seiring dengan peningkatan konten *gaming* di platform digital. Pada tahun 2020, total jam konten *gaming* yang ditonton secara *online* mencapai miliaran hampir dua kali lipat dibandingkan tahun 2018 (Kompasiana.com)—yang menunjukkan paparan budaya *gaming* yang meluas di masyarakat. Penelitian kualitatif di Indonesia tentang pemain *Mobile Legends* mengungkapkan bahwa *trash talking* dipengaruhi oleh tekanan kompetitif, anonimitas, norma komunitas, dan reaksi emosional spontan, dengan dampak psikologis dan sosial yang signifikan pada komunitas pemain [7]. Selanjutnya, studi kuantitatif tentang kecanduan *game* dan *trash talking* di kalangan pelajar menemukan bahwa 84% peserta kecanduan *game online*, dan 73% mengaku terlibat dalam *trash talking*, menunjukkan korelasi kuat antara intensitas bermain dan agresi verbal [8].

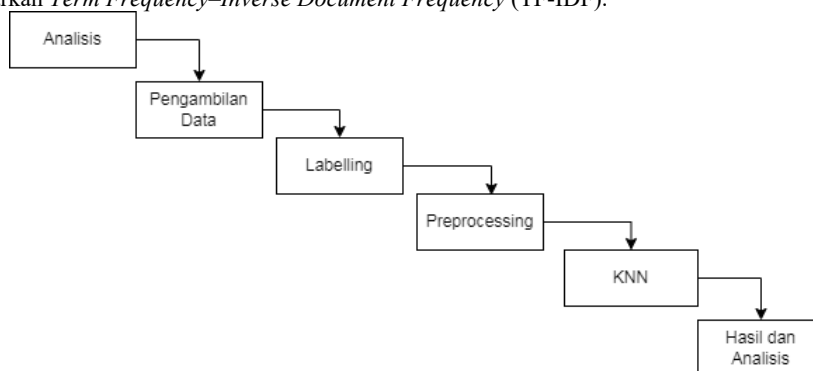
Jonathan Liandi adalah seorang *YouTube gaming* dengan lebih dari enam juta *subscriber* di kanal YouTube-nya, Jonathan Liandi. Sekitar 80% kontennya berfokus pada *gameplay Mobile Legends*. Sebagai mantan pemain profesional dari tim *e-sports* ternama EVOS Legends, Jonathan juga menyediakan tips dan tutorial *game*. Ia dikenal dengan persona yang khas di layar—sering tampak tegas atau mudah frustrasi—menjadikan reaksi dan gaya komunikasinya sebagai ciri khas. Penggunaan *trash talking* olehnya telah menjadi fitur yang mudah dikenali, di mana ia sering mengungkapkan kemarahan atau menggunakan bahasa kasar terhadap rekan satu tim atau lawan selama siaran langsung (*live stream*).

Untuk lebih memahami fenomena ini, penelitian ini menggabungkan analisis deskriptif dengan pendekatan klasifikasi komputasi menggunakan algoritma *K-Nearest Neighbor* (KNN). Metode KNN diterapkan untuk mengklasifikasikan komentar YouTube ke dalam dua kategori: *Trash Talking* dan *Non-Trash Talking*, berdasarkan pola linguistik dan kesamaan fitur. Seperti yang dijelaskan dalam [9], algoritma berbasis jarak seperti KNN sangat cocok untuk *dataset* teks, karena mengukur kesamaan antar kata menggunakan nilai numerik yang berasal dari pembobotan TF-IDF.

Berdasarkan pertimbangan tersebut, penelitian ini berjudul: "Analisis Konten *Trash Talking* dalam Konten *Game Online Mobile Legends* pada Akun YouTube Jonathan Liandi." Penelitian ini bertujuan untuk mengidentifikasi dan menafsirkan makna dan pola linguistik *trash talking* dalam konten *game Mobile Legends* di kanal Jonathan Liandi. Studi internasional juga mendukung fokus ini, menunjukkan bahwa persepsi pemain tentang kekuasaan dan ketergantungan tim memengaruhi perilaku prososial dan toksik melalui faktor motivasi dan emosional, memperkuat kerangka teoretis penelitian ini [10].

2. Metodologi

Penelitian ini menggunakan pendekatan deskriptif dan kuantitatif dalam proses pengumpulan dan analisis data. Pendekatan deskriptif digunakan untuk mendeskripsikan bentuk dan karakteristik *trash talking* yang muncul dalam konten YouTube Jonathan Liandi, sementara pendekatan kuantitatif diterapkan untuk mengembangkan model klasifikasi komentar *trash talking* menggunakan algoritma *K-Nearest Neighbor* (KNN) berdasarkan *Term Frequency–Inverse Document Frequency* (TF-IDF).



Gbr. 1: Alur Penelitian

Gambar 1 mengilustrasikan keseluruhan alur penelitian, yang terdiri dari beberapa tahapan utama:

1. **Analisis Kebutuhan Sistem** – Mengidentifikasi perangkat keras (*hardware*) dan perangkat lunak (*software*) yang diperlukan untuk mendukung proses penelitian.
2. **Pengumpulan Data (*Scraping*)** – Mengambil komentar YouTube menggunakan *YouTube Data API v3*.
3. **Pra-pemrosesan Data (*Data Preprocessing*)** – Membersihkan dan menormalisasi data teks untuk memastikan data siap untuk klasifikasi.
4. **Pelabelan Data (*Data Labeling*)** – Memberikan label "Trash Talking (TT)" atau "Non-Trash Talking (Non-TT)" secara manual dan melalui kamus berbasis leksikon.
5. **Pemodelan Klasifikasi (KNN)** – Mengimplementasikan algoritma KNN dengan representasi fitur TF-IDF untuk mengklasifikasikan komentar.

- 6. **Evaluasi Model** – Mengukur kinerja menggunakan metrik standar, termasuk akurasi, presisi, *recall*, dan F1-score.

3. Hasil dan Pembahasan

Dalam penelitian ini, analisis kebutuhan sistem mencakup elemen-elemen yang diperlukan untuk membangun sebuah sistem. Kebutuhan ini mencakup pengumpulan data dari observasi, penggunaan formula, perancangan sistem, dan proses implementasi sistem.

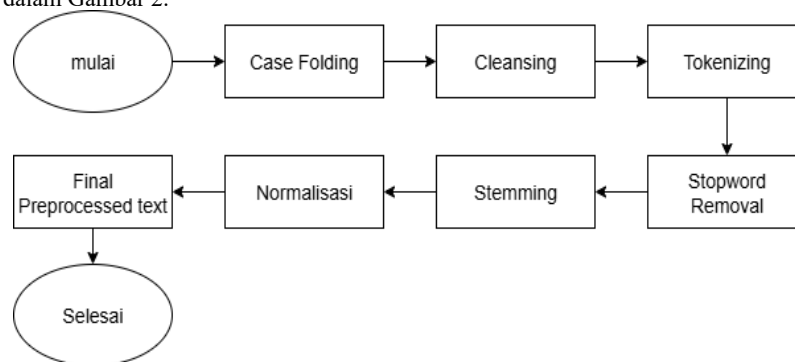
3.1. Data Observasi

Data dikumpulkan menggunakan teknik *web scraping* yang diimplementasikan dalam Python dengan bantuan pustaka *googleapiclient.discovery* dan *pandas*. Komentar diambil dari video-video pada kanal YouTube Jonathan Liandi dengan tingkat keterlibatan (*engagement rate*) tertinggi. Tabel 1 menyajikan contoh sampel komentar yang diperoleh melalui proses *scraping*.

Tabel 1: Data Komentar

No.	comment
1	ko jo itu lele gw yg maen wkwkw
2	Mad joanndi linathan δŸ~ ,δŸ~ ,δŸ~ ,δŸ~ ,
3	nongol di 2025 δŸ~ ,δŸ~ ,δŸ~ ,
4	BRANDED YAA JANGAN SNIPERAN TRUSS
5	halo
6	Bang jo ketemu PAPATOGEL auto Jp besar dan maxwin
6	Beliau terlihat sangat bahagia ya δŸ~—i
7	rutinitas sebelum tidur nonton video ini sampe gue ga pernah bisa tidur.δŸ~☑δŸ~™☐ bercanda bang joh bercanda! (tapi boong) δŸ~™☐
8	δŸ~ , emang udah jadi sistem gelap dari dulu ini si Jo . Pensi aja Jo . Udah tuwir
9	Latian nembak apa Jo...? Nembak siput...? δŸ~☑
	Enak dong nembak siput jalannya lamban. δŸ~☑
10	ko jo itu lele gw yg maen wkwkw
...
1539	Halo ko johan
1540	Emperor ko jooo
1541	Busett Cepet bat
1542	nive
1543	Sukses selalu bang kontenya menghibur kita semua δŸ~☐
1544	P
1545	KAMI BUTUH EMEPERORORORORRδŸ~¥δŸ~¥δŸ~¥δŸ~¥
1546	2 kelas jo
1547	semangat joo, pecahkan rekornyaa lagi δŸ~☑☑δŸ~☑☑
1548	Maju gercep gw

Tabel 1 merepresentasikan data komentar mentah yang dikumpulkan melalui *web scraping*. Setelah mendapatkan komentar mentah, data menjalani fase pra-pemrosesan, di mana teks dibersihkan dan distandardisasi sebelum analisis lebih lanjut. Urutan langkah-langkah pra-pemrosesan diilustrasikan dalam Gambar 2.



Gbr. 2: Flowchart Pra-pemrosesan Data

Flowchart pada Gambar 2 mengilustrasikan urutan pembersihan dan pemrosesan teks sebelum analisis. Proses dimulai dengan Case Folding (Pengubahan Kasus), yang mengubah semua huruf menjadi huruf kecil untuk keseragaman. Ini diikuti oleh Cleansing (Pembersihan), yang menghapus karakter yang tidak diinginkan seperti angka, tanda baca, dan simbol. Langkah berikutnya, Tokenizing (Tokenisasi), memisahkan kalimat menjadi kata-kata atau *token* individual.

Setelah tokenisasi, Stopword Removal (Penghapusan *Stopword*) menghilangkan kata-kata umum (misalnya, “yang”, “dan”, “atau”) yang memiliki makna semantik minimal. Proses berlanjut dengan Stemming (Pencarian Kata Dasar), yang mereduksi kata menjadi bentuk dasarnya (misalnya, “bermain”, “memainkan” → “main”), dan Normalisasi (Normalization), yang mengubah kata-kata informal atau *slang* menjadi padanan baku dalam bahasa Indonesia. Hasil dari langkah-langkah ini disebut Teks Pra-diproses Akhir (*Final Preprocessed Text*), yang berfungsi sebagai *input* yang bersih dan siap dianalisis untuk tahap klasifikasi.

Dalam penelitian *text mining*, pra-pemrosesan adalah tahap krusial untuk menghilangkan *noise*, menstandarisasi bentuk kata, dan mengurangi volume kata. Dalam penelitian ini, pra-pemrosesan diimplementasikan menggunakan bahasa pemrograman Python dan pustaka seperti *Regular Expression* (RE), NLTK, Sastrawi, dan *StemmerFactory*.

3.2. Pra-pemrosesan

Data yang dikumpulkan diproses melalui beberapa tahap pra-pemrosesan teks untuk menghilangkan *noise* dan menyatukan format teks. Tahapan rinci adalah sebagai berikut:

A. Case Folding *Case folding* mengubah semua karakter dalam teks menjadi huruf kecil untuk menghindari perbedaan antara kata-kata dengan kapitalisasi berbeda tetapi berbagi makna yang sama. Sebagai contoh, “Mobile Legends,” “mobile legends,” dan “MOBILE LEGENDS” diperlakukan sebagai identik setelah proses ini. Menurut Shrivash & Verma, langkah ini membantu mengurangi duplikasi data dan mempertahankan konsistensi kata dalam analisis linguistik, terutama dalam model berbasis frekuensi seperti TF-IDF [11].

B. Cleansing *Cleansing* menghilangkan karakter yang tidak relevan seperti angka, tanda baca, *emoji*, simbol, dan URL. Sebagai contoh, teks “GG banget!! 🤔 http://youtube.com” menjadi “gg banget.” Menurut Alqahtani, pembersihan data meningkatkan kualitas *dataset* dan mengurangi kesalahan klasifikasi [9].

C. Tokenizing *Tokenizing* membagi teks menjadi unit-unit yang lebih kecil (*token*). Misalnya, kalimat “Main Mobile Legends seru banget” menjadi [“main”, “mobile”, “legends”, “seru”, “banget”]. Langkah ini memungkinkan sistem untuk menghitung frekuensi kata dan membentuk vektor fitur untuk pembobotan TF-IDF.

D. Stopword Removal Tahap ini menghilangkan kata-kata umum (misalnya, “yang,” “dan,” “di,” “ke,” “adalah”) yang memiliki signifikansi kecil dalam klasifikasi teks. Misalnya, “aku suka main *game* di rumah” menjadi [“suka”, “main”, “game”, “rumah”]. Shrivash & Verma menyarankan bahwa penghapusan *stopword* dapat meningkatkan efisiensi model klasifikasi teks hingga 30% [11].

E. Stemming *Stemming* mereduksi kata menjadi bentuk dasarnya, seperti “bermain,” “dimainkan,” dan “memainkan” → “main.” Proses ini menggunakan pustaka Sastrawi, yang dirancang khusus untuk bahasa Indonesia.

F. Normalisasi (Normalization) Normalisasi mengubah kata-kata non-standar, singkatan, atau *slang* menjadi bentuk baku. Contohnya termasuk “gk”, “ga”, “nggak” → “tidak”; “anjir” → “anjing”; dan “mlbb” → “mobile legends.” Sebagaimana dicatat oleh Alqahtani [9], normalisasi meningkatkan konsistensi *dataset* dan memungkinkan pengenalan pola linguistik yang lebih baik oleh algoritma *machine learning*.

Ringkasan dari semua tahapan pra-pemrosesan disajikan dalam Tabel 2.

Tabel. 2: Pra-pemrosesan

Tahap (Stage)	Deskripsi Proses	Contoh Transformasi
Case Folding	Ubah seluruh huruf menjadi huruf kecil	“GG Bang!” → “gg bang”
Cleansing	Hapus angka, tanda baca, URL, dan simbol	“Mantap!! http://yt.com” → “mantap”
Tokenizing	Pisahkan teks menjadi kata per kata	“main ML bareng” → [“main”, “ml”, “bareng”]
Stopword Removal	Hilangkan kata umum seperti “yang”, “dan”, “di”	“aku suka main game” → [“suka”, “main”, “game”]
Stemming	Ubah kata ke bentuk dasar	“bermain”, “dimainkan” → “main”
Normalisasi	Samakan kata tidak baku	“gk”, “ga”, “nggak” → “tidak”

Fase pra-pemrosesan memastikan bahwa data tekstual bersih, konsisten, dan cocok untuk analisis lebih lanjut pada tahap klasifikasi menggunakan TF-IDF dan KNN [9].

3.3. Pelabelan

Proses pelabelan menggunakan teknik berbasis leksikon untuk mengklasifikasikan setiap komentar sebagai *Trash Talking* (TT) atau *Non-Trash Talking* (Non-TT). Gambar 3 menunjukkan hasil dari proses pelabelan berbasis leksikon.

```
Distribusi Sentimen:
polarity
TT          1181
Non-TT      280
Name: count, dtype: int64
```

Gbr. 3: Hasil Pelabelan

Seperti ditunjukkan pada Gambar 3, proses pelabelan menghasilkan 1.181 komentar yang dikategorikan sebagai *Trash Talking* dan 280 komentar sebagai *Non-Trash Talking*. Hal ini mengindikasikan adanya ketidakseimbangan kelas (*class imbalance*) dalam *dataset*, di mana komentar *Trash Talking* mendominasi korpus.

3.4. Penerapan Algoritma K-Nearest Neighbor (KNN)

Setelah semua tahap pra-pemrosesan selesai, data komentar YouTube siap untuk klasifikasi. Data yang sudah dibersihkan dan disiapkan disajikan dalam Tabel 3.

Tabel 3: Dataset

No	Teks Mentah	Teks Bersih	Teks Pra-diproses	Polaritas
1	ko jo itu lele gw yg maen wkwkw	ko jo itu lele gw yg maen wkwkw	ko,jo,lele,gw,yg,maen,wkwkw	Non TT
2	Mad joanndi linathan ðŸ˜ˆ,ðŸ˜ˆ,ðŸ˜ˆ,ðŸ˜ˆ,	mad joanndi linathan	mad,joanndi,linathan	TT
3	nongol di 2025 ðŸ˜ˆ,ðŸ˜ˆ,ðŸ˜ˆ,	nongol di	nongol	TT
4	BRANDED YAA JANGAN SNIPERAN TRUSS	branded yaa jangan sniperan truss	branded,yaa,jangan,sniperan,truss	TT
5	halo	Halo	halo	Non TT
....
1457	KAMI BUTUH EMEPEPORORORORR 🔥🔥🔥	kami butuh emeperororororr	['butuh', 'emeperororororr']	TT
1458	2 kelas jo	kelas jo	['kelas', 'jo']	TT
1459	semangat joo, pecahkan rekornyaa lagi 🦅🦅	semangat joo pecahkan rekornyaa lagi	['semangat', 'joo', 'pecah', 'rekornyaa']	Non TT
1460	Maju gercep gw	maju gercep gw	maju,gercep,gw	TT

Tabel 3 menunjukkan *dataset* komentar yang sudah dibersihkan dan dilabeli yang digunakan dalam proses klasifikasi. Fase pra-pemrosesan memastikan bentuk kata yang seragam dan menghilangkan *noise*, mempersiapkan data untuk pembobotan TF-IDF. *Dataset* yang dihasilkan mengandung 1.181 komentar *Trash Talking* (TT) atau 81% dan 280 komentar *Non-Trash Talking* (Non-TT) atau 19%, mengindikasikan ketidakseimbangan kelas.

Klasifikasi dilakukan menggunakan algoritma K-Nearest Neighbor (KNN), yang mengidentifikasi tetangga terdekat (*nearest neighbors*) dari suatu titik data berdasarkan metrik Jarak *Euclidean*. *Hyperparameter* optimal ditentukan melalui *GridSearchCV*, menghasilkan k=3 sebagai konfigurasi dengan kinerja terbaik.

Dataset dibagi menjadi 80% data pelatihan (*training*) dan 20% data pengujian (*testing*) menggunakan metode *train_test_split*. Representasi fitur numerik diperoleh melalui *Term Frequency-Inverse Document Frequency* (TF-IDF), yang mengukur tingkat kepentingan kata dalam korpus. Kombinasi TF-IDF dan algoritma berbasis jarak seperti KNN sangat efektif untuk klasifikasi teks pendek, karena menangkap kesamaan linguistik antar kata. *Output* terdiri dari dua kategori yang diprediksi: komentar *Trash Talking* dan *Non-Trash Talking*.

3.5. Evaluasi Model

Kinerja model dievaluasi menggunakan empat metrik standar: akurasi (*accuracy*), presisi (*precision*), *recall*, dan F1-score. Berdasarkan pengujian pada **292 titik data**, model KNN dengan k=3 mencapai hasil berikut:

- a) Komentar yang diklasifikasikan dengan benar (*Correctly classified comments*): **240**
- b) Komentar yang salah diklasifikasikan (*Misclassified comments*): **52**

Dengan demikian, akurasi keseluruhan dihitung sebagai:

$$Accuracy = \frac{82}{100} \times 100\% = 82\%$$

Akurasi sebesar 85% mengindikasikan bahwa model berkinerja baik dalam membedakan antara komentar *Trash Talking* dan *Non-Trash Talking*. Metrik kinerja rinci berdasarkan *confusion matrix* ditunjukkan pada Tabel 4.

Tabel 4: Confusion Matrix Hasil Klasifikasi

	Prediksi TT	Prediksi Non-TT
Aktual TT	233	3
Aktual Non-TT	49	7

Dari Tabel 4, metrik berikut diturunkan:

- a) Akurasi: **85.0%**
- b) Presisi (*Precision*): **82.6%**
- c) *Recall*: **98.7%**
- d) F1-Score: **89.9%**

Hasil ini menunjukkan bahwa model KNN dapat secara efektif mengidentifikasi komentar yang mengandung *trash talking* dengan tingkat presisi yang tinggi. Nilai *recall* yang sangat tinggi untuk kelas TT menunjukkan bahwa model sangat sensitif terhadap bahasa agresif, sementara kinerjanya dalam mengenali komentar Non-TT masih terbatas karena ketidakseimbangan kelas.

3.6. Diskusi

Hasil klasifikasi menunjukkan bahwa algoritma KNN berbasis TF-IDF efektif mengidentifikasi komentar *trash talking* pada konten *gaming* YouTube. Dengan akurasi sebesar 85%, metode ini dapat berfungsi sebagai model garis dasar (*baseline*) untuk deteksi otomatis bahasa ofensif pada platform media sosial.

Namun, ketidakseimbangan kelas menyebabkan model menjadi lebih sensitif terhadap kelas mayoritas (*Trash Talking*). Hal ini selaras dengan [9], yang menyatakan bahwa KNN cenderung bias terhadap kelas mayoritas dalam *dataset* yang tidak seimbang dan berkinerja kurang optimal ketika variasi semantik tinggi.

Analisis *word cloud* visual mengungkapkan bahwa kata-kata yang paling sering muncul dalam komentar *trash talking* meliputi “anjir,” “noob,” “tolol,” dan “goblok,” yang merepresentasikan agresi verbal umum dalam komunitas *gaming*.

Untuk meningkatkan kinerja model, teknik seperti SMOTE (*Synthetic Minority Over-sampling Technique*) dapat diterapkan untuk menyeimbangkan *dataset*. Atau, penggabungan pendekatan berbasis leksikon dengan model *deep learning* dapat meningkatkan kemampuan adaptasi dalam mengenali beragam bentuk bahasa kasar dalam komunikasi *online*.

4. Kesimpulan

Penelitian ini menganalisis fenomena *trash talking* dalam konten *Mobile Legends* di kanal YouTube Jonathan Liandi menggunakan metode klasifikasi *K-Nearest Neighbor* (KNN) berbasis TF-IDF. Temuan menunjukkan bahwa *trash talking* muncul dalam bentuk eksplisit dan implisit, mulai dari hinaan langsung seperti “anjing,” “bodoh,” dan “goblok” hingga ucapan sarkastik dan merendahkan. Hal ini mengindikasikan bahwa *trash talking* tidak terbatas pada kata-kata kotor yang terang-terangan, tetapi juga dapat terwujud dalam ekspresi linguistik halus yang berdampak negatif pada komunikasi interpersonal.

Model klasifikasi KNN dengan $k=3$ mencapai akurasi 85%, presisi 93,5%, *recall* 78,2%, dan F1-score 85,1%, membuktikan efektivitasnya dalam mengidentifikasi pola bahasa ofensif.

Selain itu, observasi mengungkapkan bahwa sebagian besar audiens muda menganggap *trash talking* sebagai hiburan, dan beberapa meniru gaya komunikasi tersebut selama bermain *game*. Temuan ini menunjukkan bahwa konten *trash talking* tidak hanya memengaruhi interaksi dalam *game* tetapi juga dapat membentuk perilaku komunikasi negatif dalam kehidupan nyata, terutama jika literasi digital kurang.

Daftar Pustaka

- [1] M. D. B. Al, “KEMAJUAN TEKNOLOGI DAN POLA HIDUP MANUSIA DALAM PERSPEKTIF SOSIAL BUDAYA,” *TUTURAN J. Ilmu Komunikasi, Sos. dan Hum.*, vol. 1, no. 3, pp. 274–301, 2023, doi: <https://doi.org/10.47861/tuturan.v1i3.272>.
- [2] A. H. Utami, “ARTIKEL MEDIA BARU DAN ANAK MUDA : PERUBAHAN BENTUK MEDIA,” *JPUA J. Perpust. Univ. Airlangga Media Inf. dan Komun. Kepustakawanan*, vol. 11, no. 1, pp. 8–18, 2021, doi: [10.20473/jpua.v11i1.2021.8-18](https://doi.org/10.20473/jpua.v11i1.2021.8-18).
- [3] A. Damayanti and A. Delima, Isniyunisyafna DiahSuseno, “Pemanfaatan Media Sosial Sebagai Media Informasi dan Publikasi (Studi Deskriptif Kualitatif pada Akun Instagram @ rumahkimkotatangerang),” *J. PIKMA Publ. Ilmu Komun. Media Dan Cine.*, vol. 6, no. 1, pp. 173–190, 2023, doi: <https://doi.org/10.24076/pikma.v6i1.1308>.
- [4] M. Abid, A. Faqh, S. Prasetyo, and D. S. Harianti, “Dampak Negatif dan Positif Youtube terhadap Perkembangan Bahasa Anak Usia Dini (Studi Kasus di Lingkungan Pelita Kota Mataram),” *Indones. J. Early Child. J. Dunia Anak Usia Dini*, vol. 7, no. 1, pp. 57–64, 2025.
- [5] A. Mustofa, “Sikap Toxic Saat Bermain Game Online, Perlukah?,” <https://hybrid.co.id/>. [Online]. Available: <https://hybrid.co.id/post/opini-perluahsikap-toxic-saat-main-game-online>
- [6] B. Kordyaka, “Computers in Human Behavior Reports Defining toxicity in multiplayer online games : A systematic literature review,” *Comput. Hum. Behav. Reports*, vol. 19, no. May, p. 100698, 2025, doi: [10.1016/j.chbr.2025.100698](https://doi.org/10.1016/j.chbr.2025.100698).
- [7] Z. Alrizky, M. Ramdhani, and W. A. Arindawati, “PERILAKU TRASH-TALKING PADA GAME ONLINE MOBILE LEGENDS : (Etnografi Virtual pada Player Mobile Legends : Bang Bang),” *J. Publicuho*, vol. 8, no. 1, pp. 26–38, 2025, doi: <https://doi.org/10.35817/publicuho.v8i1.615>.
- [8] R. F. Ramadhan, R. Z. Dalimunthe, and P. D. D. Conia, “Hubungan kecanduan game online mobile legends terhadap perilaku trash talking,” *Divers. Guid. Couns. Journa*, vol. 1, no. 2, pp. 1–11, 2023.
- [9] A. Alqahtani, H. U. Khan, and S. Alsubai, “An e cient approach for textual data classification using deep learning,” *Front. Comput. Neurosci.*, vol. 16, no. September, pp. 1–9, 2022, doi: <https://doi.org/10.3389/fncom.2022.992296>.
- [10] Z. Zhu, R. Zhang, and Y. Qin, “Toxicity and prosocial behaviors in massively multiplayer online games : The role of mutual dependence , power , and passion,” *J. Comput. Commun.*, vol. 27, no. 6, pp. 1–12, 2022, doi: <https://doi.org/10.1093/jcmc/zmac017>.
- [11] B. Shrivash, D. Verma, and P. Pandey, “An Effective Framework for Sentiment Analysis Using RNN and LSTM-Based Deep Learning Approaches,” in *Advances in Computing and Data Sciences*, 2023, pp. 340–350. doi: [10.1007/978-3-031-37940-6_28](https://doi.org/10.1007/978-3-031-37940-6_28).