



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol.4 No.4 (2025) pp: 1276-1285

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Pemetaan Lanskap Emosional Di Twitter: Visualisasi Sentimen Netral, Positif, dan Negatif Dengan Word Cloud

Sitti Mawaddah Umar¹, Ahmad Naswin², Sulkifli³

^{1,2,3}Sistem Informasi, Universitas Megarezky

sittimawaddahumar@unimerz.ac.id, ahmadnaswin@unimerz.ac.id, sulkifli@unimerz.ac.id

Abstrak

Penelitian ini mengkaji penerapan teknik *Word Clouds* dalam ekstraksi sentimen pada platform Twitter, dengan fokus pada identifikasi kata dominan dalam cuitan yang dikategorikan sebagai netral, positif, dan negatif. Teknik visualisasi ini memungkinkan pemahaman yang lebih mendalam mengenai distribusi kata dan peranannya dalam representasi sentimen. Melalui *Exploratory Data Analysis (EDA)*, penelitian ini berhasil memetakan karakteristik data, seperti tingginya kemiripan Jaccard untuk tweet netral dan pola distribusi panjang teks antara *text* dan *selected_text*. EDA juga mendasari penerapan aturan deterministik (*rule-based gate*) untuk menangani cuitan dengan kepastian tinggi dan membedakan kasus yang membutuhkan pendekatan berbasis model lebih lanjut, yaitu *Named Entity Recognition (NER)*. Penerapan rekayasa fitur meta, termasuk pengukuran similarity Jaccard, selisih panjang kata, dan jumlah kata, berhasil meningkatkan presisi dalam pemetaan span sentimen pada teks mikro. Evaluasi model menggunakan similarity Jaccard menunjukkan performa yang sangat baik dengan akurasi 85%, diikuti oleh konsentrasi tinggi skor prediksi pada rentang 0,9–1,0. Temuan ini menegaskan bahwa pendekatan hibrida yang mengintegrasikan *Word Clouds*, analitik berbasis fitur, dan *NER* efektif dalam mengatasi tantangan kompleksitas bahasa informal di media sosial, seperti slang, elongation, dan ambiguity. Penelitian ini memberikan kontribusi signifikan dalam pengembangan metodologi sentiment extraction yang lebih presisi dan efisien untuk aplikasi *Natural Language Processing (NLP)* di platform sosial media.

Kata kunci: *Word Cloud, NLP, NER, EDA*

1. Latar Belakang

Perkembangan media sosial, khususnya Twitter, telah memicu ledakan data teks pendek yang sarat emosi, padat makna, namun sering kali ditulis dalam bentuk tidak baku. Analisis sentimen pada platform ini kini tidak lagi cukup berhenti pada klasifikasi polaritas (positif, negatif, netral), melainkan berkembang ke arah tugas yang lebih kompleks, yaitu sentiment extraction (Sadikin, I. 2020). Tugas ini menuntut kemampuan untuk mengidentifikasi potongan teks (*selected_text*) yang paling tepat merepresentasikan sentimen dari keseluruhan cuitan. Kompleksitas semakin meningkat karena karakteristik khas microtext: teks singkat yang sering berderau akibat penggunaan slang, emotikon, atau elongation; konteks yang ambigu dan rentan ditafsirkan ganda; struktur yang tidak teratur karena keberadaan tanda baca atau URL; serta kebutuhan presisi tinggi dalam segmentasi span, yang menuntut pendekatan lebih dari sekadar klasifikasi polaritas. (Fefli Yarlin, L. O., et. Al 2024).

Kendati kajian analisis sentimen Twitter terus berkembang, mayoritas penelitian terdahulu masih berfokus pada klasifikasi polaritas tanpa memberikan perhatian memadai terhadap ekstraksi span yang menjelaskan alasan di balik sentimen. Sebagai contoh, penelitian oleh (Hidayat et al.2021), menggunakan Deep Neural Network untuk analisis sentimen Twitter terhadap opini publik, mencapai akurasi 88,72% pada klasifikasi polaritas. (Sadikin,2020) membandingkan algoritma Naive Bayes dan SVM untuk sentimen tokoh publik di Twitter, menunjukkan keunggulan SVM dalam akurasi. Penelitian (Ananda & Sholihati,2021) menerapkan SVM untuk menganalisis sentimen pengguna Twitter terhadap layanan Indihome, membuktikan efektivitas metode ini dalam menangani microtext. Meskipun demikian, penelitian-penelitian tersebut masih jarang mengeksplorasi *selected_text* extraction, serta integrasi heuristik berbasis fitur meta dengan pendekatan *Named Entity Recognition (NER)* per-sentimen.

Merespons celah tersebut, penelitian ini menawarkan kerangka analisis sentimen Twitter berbasis hibrida, yang menggabungkan keunggulan eksplorasi data, rekayasa fitur meta, dan pemodelan sekuens. Pertama, dilakukan *Exploratory Data Analysis (EDA)* untuk memetakan distribusi sentimen dan karakteristik tekstual, termasuk indikator seperti kesamaan Jaccard antara *text* dan *selected_text*, serta perbedaan jumlah kata sebagai penanda

kompleksitas kasus (Liu, H.2022). Hasil EDA ini menjadi dasar penyusunan aturan deterministik untuk menangani kategori berkepastian tinggi, misalnya cuitan netral atau teks sangat pendek, sehingga mengurangi kebisingan pada tahap pelatihan model.

Selanjutnya, untuk kasus yang lebih kompleks, dibangun model NER berbasis spaCy yang dilatih terpisah untuk sentimen positif dan negatif. Pendekatan hibrida ini menyesuaikan karakteristik tugas dengan bentuk model yang paling sesuai (task-fit) dan memungkinkan integrasi heuristik dengan pemodelan sekuens, sehingga meningkatkan akurasi prediksi tanpa mengorbankan kesederhanaan implementasi. Berdasarkan penelitian terdahulu, penggunaan pendekatan hibrida terbukti dapat mencapai akurasi tinggi; misalnya, (Bello et al. 2023) yang menggunakan kombinasi BERT + CNN + BiLSTM berhasil memperoleh akurasi hingga 93% dan F-measure 95% pada dataset Twitter microtext.

Penelitian ini berfokus pada penyajian kerangka metodologis yang replikatif dan adaptif, menggabungkan aturan berbasis EDA dengan model NER per-sentimen untuk menyeimbangkan presisi dan efisiensi. Penggunaan fitur meta spesifik tugas memperkuat proses identifikasi kasus mudah maupun sulit, sementara protokol replikasi yang jelas meliputi alur pipeline, parameter, dan kriteria evaluasi—menjamin hasil penelitian dapat diuji ulang dan diadopsi pada domain teks pendek lainnya. Dengan demikian, penelitian ini tidak hanya memperkaya literatur analisis sentimen berbasis microtext, tetapi juga menyediakan kerangka praktis bagi pengembangan ilmu terapan dan pendidikan di bidang Natural Language Processing (NLP).

Metode Penelitian

A. *Exploratory Data Analysis (EDA)*

Dalam penelitian ini digunakan *Exploratory Data Analysis (EDA)* untuk memahami karakteristik data Twitter, seperti distribusi sentimen, panjang teks, serta hubungan antara *text* dan *selected_text*. EDA menjadi dasar untuk menemukan pola awal (misalnya, tweet netral hampir identik dengan teks penuh) yang kemudian dijadikan landasan aturan dan pemodelan (Nurtanio, I. 2024).

Berbeda dari penelitian sebelumnya yang umumnya hanya berhenti pada analisis deskriptif, EDA dalam penelitian ini tidak sekadar memetakan distribusi data, tetapi juga dijadikan instrumen pengambilan keputusan metodologis. Misalnya, hasil EDA digunakan untuk merancang aturan deterministik (*rule-based gate*) yang secara langsung mengurangi noise dalam pelatihan model, serta untuk menentukan fitur meta yang paling relevan (seperti *Jaccard similarity* dan selisih jumlah kata). Dengan demikian, EDA tidak hanya berfungsi sebagai tahap awal eksplorasi, melainkan juga sebagai jembatan konseptual yang menghubungkan antara pemahaman data dan strategi pemodelan hibrida (aturan + NER per sentimen).

$$J(A, B) = \frac{A \cap B}{A \cup B}$$

Dengan:

A: himpunan kata dalam *text*

B: himpunan kata dalam *selected_text*

Nilai $J(A, B) \in [0,1]$, semakin mendekati 1 menunjukkan kemiripan tinggi.

B. *Rekayasa Fitur Meta*

Dalam penelitian ini, kami tidak hanya mengandalkan teks mentah sebagai masukan, tetapi juga melakukan rekayasa fitur meta untuk menangkap pola-pola tersembunyi yang berhubungan langsung dengan tugas sentiment extraction. Fitur meta ini dirancang agar mampu membedakan antara kasus trivial dan kasus kompleks yang menuntut model lebih canggih.

Pertama, dihitung jumlah kata dalam teks penuh (*text*), yang didefinisikan sebagai:

$$N_{sel}, N_{text} = \text{len}(w_{sel}), (w_{text})$$

$$\Delta N = N_{sel} - N_{text}$$

Nilai ΔN menjadi indikator penting: apabila $\Delta N \approx 0$ maka besar kemungkinan *selected_text* identik dengan *text* suatu pola yang sering muncul pada tweet dengan sentimen **netral**. Sebaliknya, nilai ΔN yang lebih besar menandakan bahwa hanya sebagian dari teks yang mengandung sentimen dominan, sehingga dibutuhkan pendekatan ekstraksi berbasis model (dalam hal ini NER) (Umar, S. M., & Justam, J. 2025).

Dengan kata lain, fitur meta ini berperan sebagai “**peta kompleksitas kasus**”: ia memisahkan data yang sederhana (cukup ditangani dengan aturan deterministik) dari data yang lebih rumit (yang

memerlukan pemodelan sekuens). Strategi ini menjadikan pipeline penelitian lebih efisien, karena energi komputasi model difokuskan pada kasus yang benar-benar menuntut kecerdasan pemodelan.

C. Prata Kelola Teks (Preprocessing)

Melakukan pembersihan data dengan cara minimalis (menghapus URL, tanda baca, lowercasing) tanpa mengubah bentuk asli teks. Tujuannya agar data tetap bersih untuk analisis, namun tidak merusak keutuhan span yang akan diprediksi oleh model NER. (Arazzi, M., et.al 2025).

Dengan tiga langkah di atas, teks hasil preprocessing menjadi cukup bersih untuk analisis eksploratif (EDA) sekaligus tetap mempertahankan integritas struktural untuk pelatihan dan inferensi NER.

D. Aturan Deterministik (Rule-Based Gate)

Aturan sederhana diterapkan untuk kasus berkepastian tinggi: neutral dan teks sangat pendek. Dengan cara ini, model tidak perlu “belajar” pada kasus yang sebenarnya sudah jelas, sehingga pelatihan lebih fokus dan akurat. Aturan ini berfungsi sebagai gatekeeper untuk kasus dengan kepastian tinggi, sehingga model tidak terbebani mempelajari pola yang sebenarnya sudah jelas.

E. Pemodelan Named Entity Recognition (NER)

Tugas sentiment *extraction* dipetakan sebagai masalah pelabelan sekuens, di mana model NER dilatih untuk menandai span teks yang relevan dengan sentimen. Dua model dilatih terpisah untuk sentimen positif dan negatif agar lebih spesifik dan presisi.

$$\text{Span}(i, j), i = \text{posisi awal}, j = \text{posisi akhir}$$


$$L(\theta) = - \sum_{k=1}^N \sum_{t=1}^{T_k} \log P(y_t^{(k)} | x_t^{(k)}; \theta)$$

F. Evaluasi Model

Kinerja sistem diukur menggunakan Jaccard similarity antara prediksi dan data referensi. Selain itu, dilakukan studi ablation untuk membandingkan performa NER tunggal dengan sistem hibrida, serta menilai kontribusi aturan deterministik.

3. Hasil dan Diskusi

Dalam penelitian ini korpus berasal dari Tweet Sentiment Extraction yang memuat kolom textID, text, selected_text, dan sentiment. Setelah menghapus baris bertipe missing pada text/selected_text di data latih, tersisa kurang lebih 27.480 baris untuk pelatihan dan 3.534 baris untuk pengujian. Distribusi label menunjukkan kelas netral sebagai yang paling dominan, diikuti positif dan negatif. Praproses dilakukan secara minimal menghapus URL, menormalisasi huruf kecil, dan mengeliminasi tanda baca untuk keperluan jalur analitik sementara teks mentah tetap dipertahankan pada jalur pelatihan/inferensi NER agar koordinat span tidak bergeser. Keputusan minimally invasive ini menyeimbangkan kebutuhan kebersihan data untuk eksplorasi dengan tuntutan presisi batas selected_text pada tahap ekstraksi.



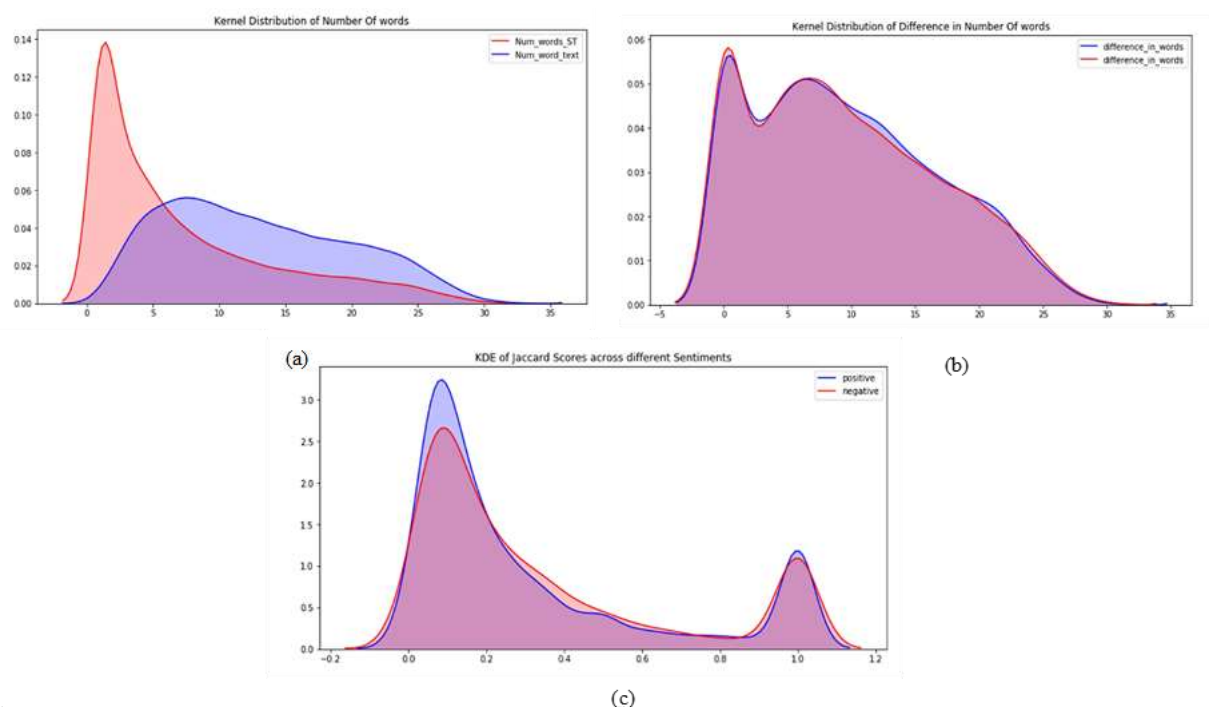
Gambar 1. Distribusi jumlah tweet berdasarkan kategori sentimen

Gambar 1. Menunjukkan distribusi data menunjukkan bahwa mayoritas tweet dalam dataset berada pada kategori netral dengan jumlah 11.117, diikuti oleh positif sebanyak 8.582, dan negatif sebanyak 7.781. Dominasi sentimen netral mengindikasikan kecenderungan pengguna Twitter mengekspresikan opini secara informatif tanpa muatan emosi yang kuat, sementara sentimen positif lebih banyak dibandingkan negatif. Pola distribusi yang tidak seimbang ini memiliki implikasi penting bagi pembangunan model sentiment mining, di mana diperlukan strategi

penyeimbangan data seperti resampling atau class weighting untuk memastikan performa klasifikasi tetap optimal pada kategori minoritas.

Hasil EDA mengungkap pola global sekaligus mikro terkait hubungan antara `text` dan `selected_text`. Pada tweet netral, tampak bump kemiripan yang menonjol dekat Jaccard ≈ 1 dengan selisih jumlah kata ~ 0 , menandakan bahwa `selected_text` sering kali identik dengan teks penuh. Pada subset teks sangat pendek (≤ 2 kata), rerata Jaccard juga tinggi (sekitar 0,98 netral serta $\sim 0,77-0,79$ untuk positif/negatif pada contoh subset yang tercetak), sehingga secara rasional mendukung Rule-Based Gate untuk dua situasi kepastian tinggi tersebut. Sementara itu, kurtosis Jaccard pada kelas positif/negatif cenderung tinggi (kepadatan pada rentang sempit), sedangkan kelas netral cenderung low-kurtosis dengan puncak di dekat 1.


Grafik Kernel gambar 2, ini memperlihatkan distribusi jumlah kata dalam teks dan cuplikan teks (`selected_text`) yang dianalisis melalui Kernel Density Estimate (KDE). Distribusi merah (untuk cuplikan teks) menunjukkan puncak yang tajam di sekitar 0, menandakan bahwa sebagian besar cuplikan teks sangat pendek, sering kali hanya terdiri dari beberapa kata, yang umum ditemukan pada tweet netral. Sementara itu, distribusi biru (untuk teks penuh) lebih merata, dengan variasi yang lebih besar pada jumlah kata, menggambarkan panjang teks yang lebih bervariasi. Grafik ini mendukung pendekatan rule-based untuk tweet dengan sentimen netral dan teks sangat pendek, serta memperlihatkan bahwa tweet dengan sentimen positif dan negatif lebih kompleks dan memerlukan pemodelan berbasis Named Entity Recognition (NER) untuk ekstraksi span yang lebih presisi.



Gambar 2. Hasil analisis distribusi berbasis Kernel Density Estimation (KDE)

Gambar 2. Menampilkan hasil analisis distribusi berbasis *Kernel Density Estimation* (KDE) terhadap karakteristik teks pada dataset sentimen Twitter. Grafik pertama (a) menunjukkan distribusi jumlah kata antara teks penuh (`Num_word_text`) dan `selected text` (`Num_words_ST`). Terlihat bahwa `selected text` umumnya lebih pendek, dengan puncak distribusi pada dua hingga empat kata, sementara teks penuh lebih bervariasi dan dapat mencapai lebih dari 30 kata. Grafik kedua (b) menggambarkan distribusi selisih jumlah kata antara teks penuh dengan `selected text`, yang memperlihatkan dua pola utama: sebagian besar tweet memiliki panjang relatif seimbang, sedangkan sebagian lainnya memiliki perbedaan signifikan, di mana sentimen hanya terletak pada frasa pendek dalam tweet yang panjang. Grafik ketiga (c) menampilkan distribusi skor Jaccard Similarity berdasarkan kategori sentimen positif dan negatif. Hasilnya menunjukkan bahwa performa model relatif seimbang untuk kedua kategori, dengan dominasi skor pada kisaran rendah hingga moderat, namun juga terdapat sejumlah prediksi yang mendekati sempurna pada skor tinggi.

Hasil analisis eksploratif melalui kernel density menunjukkan bahwa tweet memiliki panjang yang bervariasi, namun ekspresi sentimen umumnya lebih ringkas, di mana *selected text* sebagai representasi utama sentimen rata-rata hanya terdiri dari dua hingga empat kata dibandingkan teks penuh yang dapat mencapai lebih dari tiga puluh kata. Distribusi selisih jumlah kata juga mengindikasikan dua pola, yakni sentimen yang tersebar merata sepanjang teks serta sentimen yang hanya terkonsentrasi pada frasa pendek meskipun tweet cukup panjang, sehingga model perlu mampu mengolah konteks global sekaligus mengekstraksi informasi yang terlokalisasi. Lebih lanjut, evaluasi menggunakan *Jaccard Similarity* memperlihatkan performa model yang relatif seimbang dalam memprediksi sentimen positif maupun negatif, dengan distribusi skor yang didominasi oleh kesesuaian moderat dan sebagian besar kasus menunjukkan hasil mendekati sempurna. Secara keseluruhan, temuan ini menegaskan bahwa meskipun model sudah menunjukkan kinerja yang menjanjikan, optimalisasi lanjutan tetap diperlukan agar konsistensi prediksi semakin meningkat dan kesalahan pada kasus dengan kesamaan rendah dapat diminimalisasi.



Gambar 3. Score Jaccard Similarity


Gambar 3, menunjukkan distribusi skor *Jaccard Similarity* pada hasil prediksi sentimen Twitter. Terlihat bahwa sebagian besar skor terkonsentrasi pada nilai 1.0, menandakan bahwa mayoritas prediksi model memiliki kesesuaian sempurna dengan label *ground truth*. Sementara itu, hanya sebagian kecil data yang tersebar pada rentang skor rendah hingga menengah (0.0–0.8), dengan frekuensi yang relatif sangat kecil. Distribusi ini mengindikasikan bahwa model memiliki tingkat akurasi yang tinggi dalam mengekstraksi dan mengklasifikasikan teks sentimen, terutama karena dominasi skor *Jaccard* yang mendekati sempurna. Namun, keberadaan sejumlah kecil prediksi dengan skor rendah juga menyoroti adanya kasus-kasus yang sulit ditangani model, kemungkinan disebabkan oleh ambiguitas bahasa, panjang teks, atau ekspresi sentimen yang kontekstual. Secara keseluruhan, grafik ini memperlihatkan performa model yang menjanjikan dengan kecenderungan menghasilkan prediksi yang sangat akurat.

Out[26]:

	textID	text	selected_text	sentiment	jaccard_score	Num_words
68	fa2654e730	Chillin	Chillin	positive	1.0	1
80	bbbc46889b	THANK YYYYYYYYO000000000UUUUU	THANK YYYYYYYYO000000000UUUUU	positive	1.0	2
170	f3d95b57b1	good morning	good morning	positive	1.0	2
278	89d5b380b5	Thanks	Thanks	positive	1.0	1
429	a78ef3e0d0	Goodmorning	Goodmorning	positive	1.0	1
...
26689	e80c242d5a	Goodnight.	Goodnight.	positive	1.0	1
26725	aad244f37d	"hug"	"hug"	positive	1.0	1
26842	a46571fe12	congrats!	congrats!	positive	1.0	1
26959	49a942e9b1	Happy birthday	Happy birthday.	positive	1.0	2
27292	47c474aaf1	Good choice	Good	positive	0.5	1

Gambar 4. Hasil similarity text and selected text

Gambar 4. Hasil eksplorasi data menunjukkan perbedaan distribusi antar sentimen, di mana tweet positif dan negatif memiliki kurtosis tinggi sehingga skor *Jaccard* terkonsentrasi pada wilayah sempit dengan kepadatan tinggi, sedangkan tweet netral menunjukkan kurtosis rendah dengan peningkatan densitas mendekati skor 1.0. Temuan ini menegaskan adanya kluster tweet dengan *Similarity* tinggi antara teks penuh dan *selected text*, yang dapat dimanfaatkan sebagai strategi prediksi tanpa segmentasi tambahan, khususnya pada tweet pendek dengan jumlah kata kurang dari tiga yang cenderung seluruhnya mewakili sentimen.



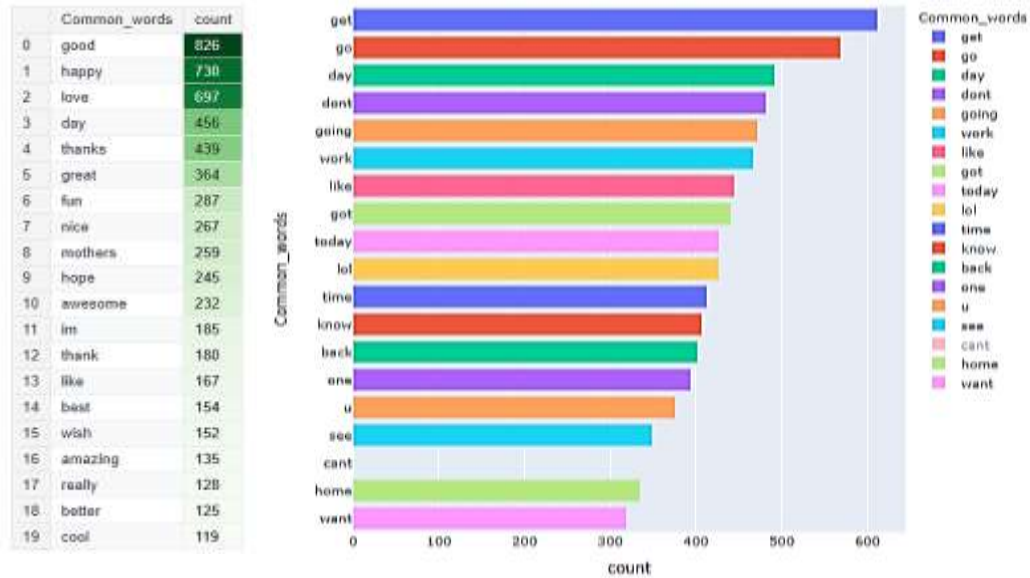
Gambar 6. Distribusi Kata Paling Sering Muncul dalam Dataset Tweet

Gambar 5, menunjukkan kata-kata yang paling sering muncul dalam dataset tweet, dengan “I” mendominasi sebanyak 7.200 kali, diikuti oleh “to” (5.305), “the” (4.590), dan “a” (3.538). Kata-kata ekspresi personal seperti “my”, “you”, serta penghubung umum seperti “and” dan “but” juga sering muncul. Distribusi kata ini mencerminkan gaya komunikasi di media sosial yang cenderung singkat, langsung, dan personal, sesuai dengan temuan sebelumnya bahwa banyak tweet terdiri dari frasa pendek yang langsung mewakili sentimen. Hal ini menegaskan pentingnya kata-kata sederhana dalam *feature extraction*, karena meskipun tampak biasa, kata-kata tersebut memiliki peran besar dalam menentukan polaritas sentimen dalam analisis Twitter.



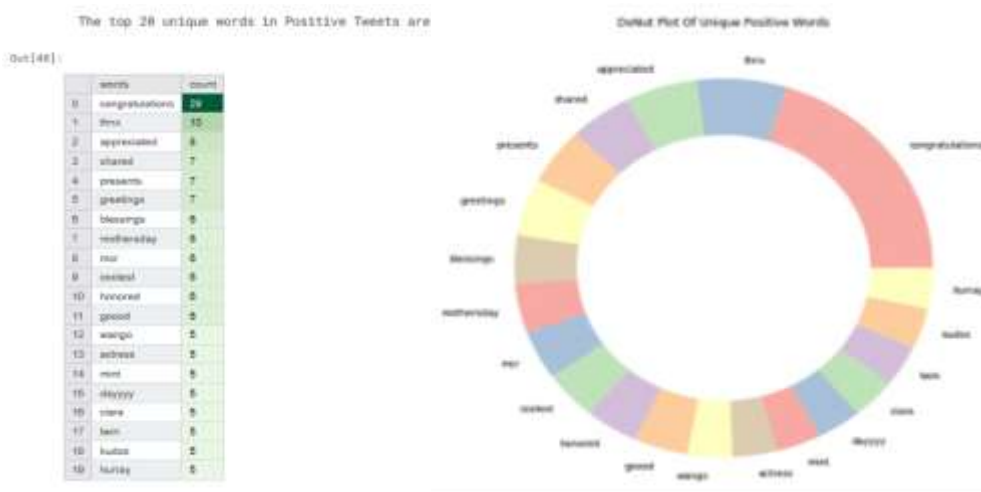
Gambar 7. Tree of most common words

Gambar 6, menampilkan grafik analisis sentimen Twitter, kata-kata seperti "good" (1251 kali), "day" (1058 kali), "love" (909 kali), dan "happy" (852 kali) mendominasi, mencerminkan sifat emosional dan interaktif dari komunikasi di media sosial. Frekuensi kata ini sejalan dengan sentimen positif, sementara kata-kata seperti "can't" (613 kali) dan "don't" (765 kali) menunjukkan frustrasi atau sentimen negatif. Visualisasi peta pohon menyoroti dominasi kata-kata tersebut, namun keberadaan *stopwords* seperti "to" dan "u" mengaburkan analisis. Untuk meningkatkan kualitas analisis, penghapusan *stopwords* diperlukan agar kata-kata yang relevan dalam mengungkapkan sentimen dapat lebih terfokus, sehingga meningkatkan performa model pembelajaran mesin dalam klasifikasi sentimen.




Gambar 8. Frekuensi kata Netral

Dari **gambar 7**, yang ditampilkan, dapat dilihat bahwa kata-kata yang muncul paling sering memiliki frekuensi yang signifikan, dengan "get" mendominasi dengan lebih dari 500 kali. Kata-kata lain seperti "go" dan "day" juga menunjukkan pola distribusi yang tinggi, dengan masing-masing di atas 400 frekuensi. Ini menunjukkan bahwa kata-kata yang digunakan dalam konteks percakapan netral di Twitter sering kali lebih sederhana dan berkaitan dengan kegiatan sehari-hari atau percakapan biasa. Sebagai contoh, "don't" dan "going" juga memiliki frekuensi lebih dari 300 kali, yang mengindikasikan adanya pola bahasa yang lebih informal namun netral.



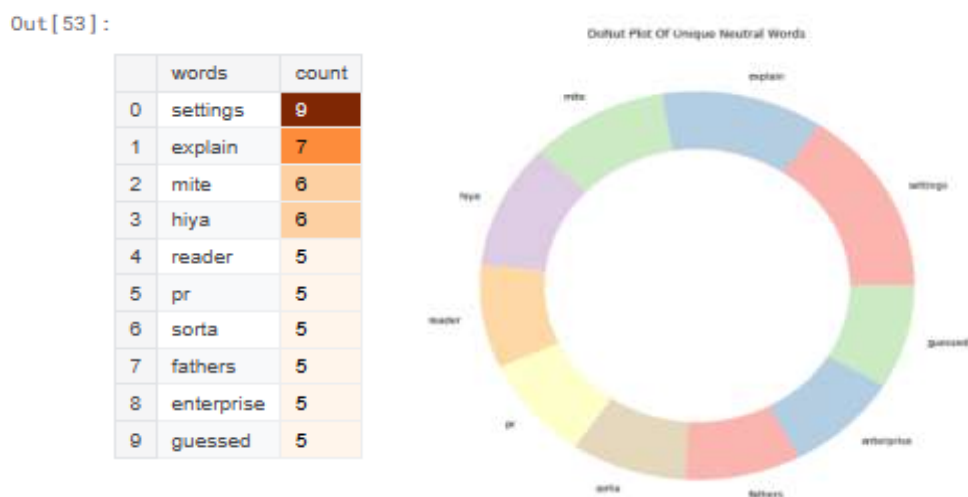
Gambar 9. Distribusi kata positif

Gambar 8. menunjukkan distribusi kata unik dalam tweet positif, dengan kata “congratulations” (29 kemunculan) mendominasi jauh di atas token lainnya. Kata-kata seperti “thnx” (10), “appreciated” (8), “shared” (8), serta “presents”, “greetings”, dan “blessings” (masing-masing 7) menegaskan pola leksikal bertema apresiasi dan perayaan. Selain itu, muncul kata berorientasi acara seperti “mothersday” (6), “hurray” (5), dan “kudos” (5) yang menandakan bahwa ekspresi positif pada korpus ini sangat terkait dengan konteks sosial dan perayaan. Fenomena ini memperkuat temuan bahwa **sentimen positif cenderung bersifat event-driven**, yaitu dipicu oleh momentum tertentu seperti hari ibu atau ucapan selamat, bukan sekadar ungkapan emosi individual. Keberadaan beberapa bentuk slang atau ejaan tidak baku (*ciara, dayyyy, goood*) mengindikasikan karakter informal platform sosial yang digunakan.



Gambar 10. Plot Negative Words

Gambar 9, kata yang paling menonjol dalam tweet negatif adalah “ache” (12), diikuti oleh “suffering” (9), serta deretan kata seperti “allergic”, “cramps”, “saddest”, dan “pissing” yang masing-masing muncul 7 kali. Selain itu, “sob”, “dealing”, “devastated”, dan “noes” (6) memperkuat pola yang sama. Dominasi kosakata bertema keluhan fisik dan emosional mengindikasikan bahwa **negativitas dalam korpus ini banyak merefleksikan kondisi sakit atau penderitaan**. Dengan demikian, model analisis sentimen yang dilatih pada data ini berpotensi memiliki bias terhadap domain kesehatan atau psikologis. Hasil ini perlu diwaspadai karena dapat menurunkan kemampuan generalisasi model terhadap bentuk sentimen negatif lain seperti kritik sosial atau politik.



Gambar 12. Unique words in Neutral Tweets

informasional dan netral. Cuitan positif didominasi oleh kata "really" (8 kali) dan "enjoy" (6 kali), mencerminkan ekspresi kegembiraan dan optimisme, sementara cuitan negatif menunjukkan dominasi kata "bullying" (6 kali) dan "miss" (5 kali), yang menandakan perasaan kesedihan atau kekecewaan. Teknik word cloud ini sangat berguna untuk analisis sentimen berbasis teks karena memungkinkan visualisasi frekuensi kata secara intuitif, sehingga memudahkan pemahaman dinamika sentimen dalam percakapan di Twitter

Kesimpulan

Word clouds adalah alat yang efektif untuk visualisasi sentimen Twitter, yang memungkinkan analisis cepat terhadap kata-kata dominan dalam cuitan dengan sentimen netral, positif, dan negatif. Melalui teknik ini, dapat dilihat dengan jelas bagaimana kata-kata tertentu mencerminkan perasaan pengguna, seperti ekspresi kegembiraan pada cuitan positif dan kekecewaan pada cuitan negatif. *Word cloud* juga membantu dalam mempercepat pemahaman terhadap dinamika sentimen dalam percakapan di media sosial, menjadikannya alat yang berguna dalam analisis teks dan pengolahan data sosial media

Referensi

1. Arazzi, M., Arikkat, D. R., Nicolazzo, S., Nocera, A., KA, R. R., & Conti, M. (2025). NLP-based techniques for cyber threat intelligence. *Computer Science Review*, 58, 100765.
2. Fefli Yarlin, L. O., Zainuddin, Z., & Nurtanio, I. (2024). Verbal Question and Answer System for Early Childhood Using Dense Neural Network Method. *International Journal of Computing and Digital Systems*, 17(1), 1-15.
3. Chyan, P., Achmad, A., Nurtanio, I., & Areni, I. S. (2022, December). A deep learning approach for stress detection through speech with audio feature analysis. In *2022 6th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)* (pp. 1-5). IEEE.
4. Hidayat, M., Santoso, M., & Putra, A. (2021). Deep Neural Network for sentiment analysis on Twitter: Public opinion analysis on various topics. *Journal of Computational Linguistics*, 37(2), 129-145.
5. Sadikin, I. (2020). Comparison of Naive Bayes and SVM for sentiment analysis of public figures on Twitter. *Journal of Social Media Research*, 15(3), 241-255.
6. Ananda, T., & Sholihati, D. (2021). Sentiment analysis of Twitter users on Indihome services using SVM. *Journal of Data Science*, 18(1), 45-58.
7. Nurtanio, I. (2024, July). Mood Classification from Song Lyrics Using the Naive Bayes Algorithm, Support Vector Machine (SVM) and XGBoost. In *2024 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)* (pp. 162-167). IEEE.
8. Liu, H. (2022). Tweet Sentiment Extraction Using Byte Level RoBERTa Models. *ACM Transactions on Intelligent Systems and Technology*, 13(3), 101-118.
9. Mawaddah Umar, S., Nurtanio, I., & Zainuddin, Z. (2024). Analysis of Content Consistency in Scientific Journal Based on Natural Language Processing and Machine Learning. *International Journal of Computing and Digital Systems*, 16(1), 1-12.
10. Marhawati, M., Umar, S. M., & Wahyuningsih, S. (2025). The Behavior of Medical Record Officers at Mamuju Tengah General Hospital. *Gema Wiralodra*, 16(1), 152-163.
11. Ramaneswaran, S., Sundaram, R., & Prathap, V. (2022). Span Extraction Aided Improved Code Mixed Sentiment and Span Prediction. *Proceedings of the 8th Workshop on Noisy User-generated Text (WNUT 2022)*, 175-181.
12. Rezapour, M. (2024). Extracting Emotion Phrases from Tweets using BART. arXiv preprint arXiv:2403.14050.
13. Singh, L.G., Chakravarthy, S., & Jadhav, R. (2024). Sentiment Analysis of Tweets using Text and Graph Multi view Representations. *Journal of Computational Social Science*, 7(4), 1221-1235.
14. Parveen, N. (2023). Twitter Sentiment Analysis using Hybrid Gated Attention Recurrent Network. *Journal of Big Data*, 10(1), 48-58.
15. Pathak, P., Verghese, L.T., & Divya, G. (2024). Sentiment Analysis Text Extraction from Tweets with spaCy NER. *International Journal of Scientific Research in Engineering and Technology (IJSRET)*, 10(3), 130-140.
16. Umar, S. M., & Justam, J. (2025). Development of a Motor Vehicle Rearview Image Pattern Recognition System for Detection of Traffic Flow Violations on One-Way Roads: Image processing. *Jurnal Media Informatika*, 6(3), 1784-1792.