

BAB IV

HASIL DAN PEMBAHASAN

4.1 Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan dengan mengambil komentar dari video YouTube yang membahas kebijakan monetisasi YouTube Partner Program (YPP). Data dikumpulkan menggunakan metode web scraping dengan memanfaatkan YouTube Data API v3, dengan kata kunci pencarian seperti "monetisasi YouTube", "syarat YPP", dan "cara monetisasi channel". Proses scraping menghasilkan empat atribut data yaitu nama akun penulis komentar (author), isi komentar (comment), jumlah likes, dan waktu publikasi komentar (published_at).

Data yang berhasil dikumpulkan berjumlah 6.985 baris komentar mentah dalam Bahasa Indonesia dengan rentang waktu dari Agustus 2024 hingga April 2026. Seluruh data disimpan dalam format spreadsheet (.xlsx) dengan nama file dataMonetisasi.xlsx untuk kemudahan pengolahan pada tahapan berikutnya.

Tabel 4. 1 Statistik Awal Data Komentar Youtube

Keterangan	Jumlah
Total baris data mentah yang terkumpul	6.985
Rentang waktu pengumpulan data	Agustus 2024 – April 2026
Data duplikat (berdasarkan kolom comment)	1.395
Data unik setelah penghapusan duplikat	5.590
Data valid setelah dropna() pada kolom hasil preprocessing	5.464
Atribut data	Author, comment, like, published at

Berdasarkan Tabel 4.1, dari total 6.985 komentar yang berhasil dikumpulkan, ditemukan 1.395 data duplikat yang perlu dihapus. Setelah proses deduplikasi menghasilkan 5.590 data unik, kemudian dilakukan pembersihan lanjutan menggunakan fungsi dropna() untuk membuang baris yang menjadi

kosong (missing value) pada salah satu tahap preprocessing, misalnya karena seluruh isi komentar hanya berupa URL/emoji yang terhapus pada tahap cleaning, atau seluruh kata dalam komentar merupakan stopword sehingga hasil stopword removal menjadi kosong sehingga data akhir yang digunakan dalam analisis berjumlah 5.464 komentar.

4.2 Pra-pemrosesan Data (Preprocessing)

Tahap pra-pemrosesan data merupakan tahap kritis dalam analisis sentimen karena kualitas data mentah sangat mempengaruhi performa model klasifikasi. Data komentar YouTube umumnya bersifat informal, mengandung singkatan, emoji, URL, dan simbol-simbol yang tidak bermakna secara linguistik. Pra-pemrosesan dilakukan secara bertahap meliputi: (1) penghapusan duplikat, (2) cleaning, (3) case folding, (4) normalisasi, (5) tokenisasi, dan (6) stopword removal. Proses ini diimplementasikan menggunakan Python dengan memanfaatkan library NLTK, dan kamus normalisasi kosakata tidak baku Bahasa Indonesia Faisal et al. (2025).

4.2.1 Tahap Preprocessing

- a. Penghapusan Duplikat: Tahap pertama preprocessing adalah identifikasi dan penghapusan komentar yang memiliki isi teks identik (exact duplicate). Duplikasi pada dataset komentar YouTube umumnya terjadi akibat komentar promosi atau spam yang dikirim oleh akun yang sama secara berulang di berbagai video. Penghapusan duplikat dilakukan berdasarkan kolom comment menggunakan fungsi `drop_duplicates()` pada library Pandas. Dari total 6.985 komentar mentah yang terkumpul, ditemukan 1.395 komentar duplikat sehingga setelah tahap ini tersisa 5.590 komentar unik yang kemudian diproses pada tahap berikutnya.
- b. Cleaning : Proses pembersihan data dari karakter-karakter yang tidak relevan seperti URL (`http/https`), emoji, simbol khusus, tanda baca berlebih, angka, dan spasi ganda. Tahap ini memastikan hanya teks alfanumerik yang tersisa untuk diproses lebih lanjut.

- c. Case Folding : Mengubah seluruh huruf menjadi huruf kecil (lowercase) untuk menyeragamkan bentuk teks. Misalnya "YouTube", "YOUTUBE", dan "youtube" akan diperlakukan sebagai token yang sama.
- d. Normalisasi : Mengubah kata tidak baku atau singkatan ke bentuk baku menggunakan kamus normalisasi yang diunduh dari repositori GitHub `analysisdatasentiment/kamus_kata_baku` (file `kamuskatabaku.xlsx`). Contoh: "yg" → "yang", "jdi" → "jadi", "liat" → "lihat", "bang" → "abang", "gmn" → "bagaimana".
- e. Tokenisasi : Memecah teks menjadi unit-unit kata (token) yang lebih kecil menggunakan metode word tokenization berbasis whitespace dan tanda baca.
- f. Stopword Removal : Menghapus kata-kata umum yang tidak memiliki makna kontekstual dalam analisis sentimen, seperti "yang", "di", "ke", "dan", "saya", "itu", menggunakan daftar stopwords Bahasa Indonesia dari library NLTK (`nltk.corpus.stopwords, bahasa 'indonesian'`).

4.2.2 Contoh Data Sebelum dan Sesudah Preprocessing

Berikut perbandingan data komentar asli sebelum dan sesudah melalui tahap pra-pemrosesan :

Tabel 4. 2 Contoh Data Mentah

No	Author	Komentar
1	@michaelsugiharto	Gabung ke WA Komunitas Youtube disini 📄 https://teknobie.com/komunitas
2	@Yeni-q4s	Kenapa channel saya jdi sepi penoton ya. Bg_JAEY official
3	@aguswakul1	Mantap..sangat bermanfaat

Tabel 4. 3 Hasil Preprocessing Per Tahapan

No	Cleaning	Case Folding	Normalisasi	Stopword Removal	Sentimen
1	Gabung ke WA Komunitas Youtube disini	gabung ke wa komunitas youtube disini	gabung ke wa komunitas youtube disini	gabung wa komunitas youtube	Netral
2	Kenapa channel saya jdi sepi penoton ya BgJAEY official	kenapa channel saya jdi sepi penoton ya bgjaey official	kenapa channel saya jadi sepi penoton ya bgjaey official	channel sepi penoton ya bgjaey official	Negatif
3	Mantapsangat bermanfaat	mantapsangat bermanfaat	mantapsangat bermanfaat	mantapsangat bermanfaat	Positif

Berdasarkan Tabel 4.2 dan 4.3, proses preprocessing secara signifikan mereduksi noise sekaligus mengurangi jumlah data dari 6.985 menjadi 5.464 komentar valid. Pada tahap penghapusan duplikat, sebanyak 1.395 komentar identik berhasil diidentifikasi dan di hapus, menyisakan 5.590 komentar unik. Emoji (❤️👉), URL (<https://...>), karakter khusus, dan kata-kata tidak bermakna berhasil dihilangkan pada tahap cleaning. Kata tidak baku seperti "jdi", "liat", "yg", "aamin", dan "org" berhasil dinormalisasi menjadi bentuk baku "jadi", "lihat", "yang", "amin", dan "orang". Setelah tahap stopwords removal, baris yang menjadi kosong (missing value) dibuang menggunakan dropna(), sehingga diperoleh 5.464 komentar valid yang siap dianalisis.

4.2.3 Visualisasi Word Cloud Sebelum dan Sesudah Preprocessing

Visualisasi word cloud pada Gambar 4.1 menggambarkan perbandingan frekuensi kata sebelum dan sesudah tahap pra-pemrosesan. Ukuran kata dalam

word cloud berbanding lurus dengan frekuensi kemunculannya dalam keseluruhan dataset.



Gambar 4. 1 Word Cloud Sebelum dan Sesudah Preprocessing

Dari Gambar 4.1, terlihat jelas perbedaan signifikan antara sebelum dan sesudah preprocessing. Sebelum preprocessing, kata-kata stopwords seperti "bang", "saya", "yang", "untuk", "tapi", dan "ini" mendominasi visualisasi meskipun tidak memiliki makna semantik yang relevan dengan topik monetisasi. Setelah preprocessing, kata-kata yang lebih substantif muncul ke permukaan seperti "semoga", "abang", "pemula", "konten", "monetisasi", "video", "channel", "subscriber", dan "tayang", yang secara langsung relevan dengan topik kebijakan monetisasi YouTube Partner Program (Firdaus & Trisnawarman, 2025) (Sumartha, 2025).


4.3 Pelabelan Data (Data Labelling)

Proses pelabelan data dilakukan secara otomatis menggunakan model IndoBERT yang telah dilatih khusus untuk klasifikasi sentimen Bahasa Indonesia, yaitu mdhugol/indonesia-bert-sentiment-classification yang diakses melalui Hugging Face pipeline. Proses pelabelan dijalankan dalam batch berukuran 32 komentar dengan parameter `truncation=True` untuk menangani komentar yang melebihi batas panjang token model. Seluruh komentar hasil preprocessing yang valid diproses secara otomatis tanpa verifikasi manual mengingat skala dataset yang besar. Model ini menghasilkan tiga label yang dipetakan menjadi LABEL_0 =

Positif, LABEL_1 = Netral, dan LABEL_2 = Negatif (Wilie, et al., 2020) Koto et al. (2020).

Tabel 4. 4 Distribusi Label Sentimen Hasil Pelabelan

Label Sentimen	Jumlah Data	Persentase (%)	Keterangan
Positif	2.549	46,65%	Dukungan, apresiasi, semangat
Netral	1.955	35,78%	Informasi, pertanyaan, deskripsi
Negatif	960	17,57%	Keluhan, kritik, ketidakpuasan
Total	5.464	100%	-



Gambar 4. 2 Distribusi Sentimen Total Hasil Pelabelan data

Visualisasi pada Gambar 4.2 memperlihatkan secara grafis dominasi kelas Positif dibandingkan kelas Netral dan Negatif pada keseluruhan data hasil pelabelan.


Berdasarkan Tabel 4.4, distribusi kelas menunjukkan ketidakseimbangan (class imbalance) dengan kelas Positif mendominasi sebesar 46,65%, diikuti Netral 35,78%, dan Negatif 17,57%. Dominasi sentimen positif mencerminkan budaya

komunitas kreator YouTube Indonesia yang cenderung saling mendukung dan memberikan semangat. Ketidakseimbangan kelas ini ditangani pada tahap pelatihan model menggunakan teknik class weighting agar model tidak bias terhadap kelas mayoritas.

4.4 Klasifikasi Aspek (Aspect-Based Sentiment Analysis)

Setelah pelabelan sentimen, setiap komentar diklasifikasikan ke dalam enam kategori aspek menggunakan pendekatan berbasis aturan kata kunci (rule-based keyword matching). Sebuah komentar diberi label aspek pertama yang kata kuncinya ditemukan di dalam teks komentar tersebut. Untuk komentar yang tidak mengandung kata kunci pada kategori manapun, sistem menetapkan aspek secara round-robin (bergiliran) di antara keenam kategori agar setiap komentar tetap memiliki label aspek. Pendekatan berbasis kata kunci ini merupakan metode yang umum digunakan untuk identifikasi aspek secara sederhana dan interpretatif sebelum diproses lebih lanjut oleh model klasifikasi sentimen (Puvvula & Rodda, 2024). Identifikasi aspek ini merupakan inti dari pendekatan Aspect-Based Sentiment Analysis (ABSA) yang memungkinkan analisis opini pada level yang lebih granular dibandingkan analisis sentimen konvensional.

Enam aspek yang diidentifikasi merepresentasikan dimensi-dimensi utama diskusi komunitas kreator YouTube Indonesia terkait kebijakan monetisasi, yaitu: (1) Dukungan Komunitas & Semangat, (2) Syarat & Kebijakan Monetisasi, (3) Apresiasi Konten Edukasi, (4) Channel & Performa Konten, (5) Engagement Penonton, dan (6) Bantuan Teknis & Akun.



Gambar 4. 3 Distribusi Aspek Klasifikasi Komentar terkait Kebijakan Monetisasi

Tabel 4. 5 Distribusi Komentar per Aspek

No	Aspek	Jumlah Komentar	Persentase (%)
1	Dukungan Komunitas & Semangat	1.611	29,48%
2	Syarat & Kebijakan Monetisasi	1.141	20,88%
3	Apresiasi Konten Edukasi	1.064	19,47%
4	Channel & Performa Konten	1.020	18,67%
5	Engagement Penonton	335	6,13%
6	Bantuan Teknis & Akun	293	5,36%
	Total	5.464	100%

Dari Gambar 4.2 dan Tabel 4.5, aspek "Dukungan Komunitas & Semangat" mendominasi dengan 1.611 komentar (29,48%), menunjukkan bahwa komunitas kreator YouTube Indonesia sangat aktif dalam memberikan motivasi dan semangat satu sama lain. Aspek "Syarat & Kebijakan Monetisasi" berada di posisi kedua (20,88%), mencerminkan tingginya keingintahuan dan antusiasme kreator terhadap

persyaratan YPP. Aspek dengan jumlah terendah adalah "Bantuan Teknis & Akun" (5,36%), yang menunjukkan bahwa meski jumlahnya kecil, permasalahan teknis tetap menjadi isu yang perlu diperhatikan oleh YouTube.

4.5 Implementasi dan Evaluasi Model Klasifikasi

4.5.1 Pembagian Data Training dan Testing

Data sebanyak 5.464 komentar berlabel dibagi dengan rasio 70:15:15 (training:validation:testing) melalui dua tahap `train_test_split` dengan `random_state=42` (tanpa stratifikasi kelas). Tahap pertama membagi 70% data untuk training dan 30% sisanya menjadi data sementara; tahap kedua membagi data sementara tersebut menjadi 15% validation dan 15% testing. Pembagian ini menghasilkan 3.824 data training, 820 data validation, dan 820 data testing. Validation set digunakan untuk memantau performa IndoBERT selama pelatihan dan memilih model terbaik (`load_best_model_at_end`), sedangkan testing set yang berjumlah sama untuk kedua model digunakan untuk evaluasi final SVM maupun IndoBERT.

Tabel 4. 6 Pembagian Data Training, Validation dan Testing


Set Data	Jumlah	Persentase
Training Set	3.824	70%
Validation Set	820	15%
Testing Set	820	15%
Total	5.464	100%

4.5.2 Model Support Vector Machine (SVM)

Model Support Vector Machine (SVM) diimplementasikan menggunakan kernel Linear dengan parameter $C=1.0$ (default). Sebelum proses pelatihan, data direpresentasikan sebagai vektor numerik menggunakan metode `CountVectorizer` (menghitung frekuensi kemunculan kata/term frequency tanpa pembobotan IDF,

menggunakan n-gram range (1,2) tanpa pembatasan jumlah fitur maksimum, konfigurasi lain mengikuti default library Scikit-learn). SVM berfungsi sebagai tolok ukur bawah yang harus dapat dilampaui oleh IndoBERT untuk memvalidasi keunggulan pendekatan deep learning pada domain ini Faisal et al. (2025).

Confusion matrix hasil pengujian model SVM pada data testing ditampilkan pada Gambar 4.3:



Gambar 4. 4 Confusion Matrix Model SVM

Tabel 4. 7 Hasil Klasifikasi SVM per Kelas Sentimen

Kelas	TP	FP	FN	Precision	Recall	F1-Score
Negatif	69	43	47	0,616	0,595	0,605
Netral	224	69	82	0,764	0,732	0,748
Positif	343	72	55	0,827	0,862	0,844
Accuracy						0,776 (77,6%)


Weighted Avg	-	-	-	0,774	0,776	0,774
--------------	---	---	---	-------	-------	-------

Berdasarkan Gambar 4.3 dan Tabel 4.7, model SVM mencapai akurasi keseluruhan 77.6% dengan performa yang bervariasi antar kelas. Kelas Positif mendapatkan F1-Score tertinggi (0,844) karena memiliki jumlah sampel terbesar dalam training set. Sebaliknya, kelas Negatif mendapatkan F1-Score terendah (0.605) akibat jumlah data yang relatif lebih sedikit sehingga SVM kurang optimal dalam mempelajari pola komentar negatif. Hal ini merupakan dampak nyata dari ketidakseimbangan kelas pada data.

4.5.3 Model IndoBERT

IndoBERT merupakan model bahasa berbasis arsitektur BERT (Bidirectional Encoder Representations from Transformers) yang telah di-pretrain secara khusus menggunakan korpus teks Bahasa Indonesia berskala besar. Model ini dikembangkan oleh Koto et al. (2020) melalui IndoNLU Benchmark dan terbukti unggul dalam berbagai tugas NLP Bahasa Indonesia. Kemampuan memahami konteks kalimat secara bidireksional menjadi keunggulan utama IndoBERT dibandingkan pendekatan bag-of-words seperti CountVectorizer Devlin et al. (2019).

Pada penelitian ini, IndoBERT digunakan dengan metode fine-tuning pada data komentar YouTube yang telah dilabeli. Konfigurasi fine-tuning yang digunakan: learning rate = $2e-5$, batch size = 8, maksimum panjang token = 128, dan jumlah epoch = 3. Proses training menggunakan GPU untuk mempercepat komputasi. Confusion matrix model IndoBERT ditampilkan pada Gambar 4.4:



Gambar 4. 5 Confusion Matrix Model IndoBERT

Tabel 4. 8 Hasil Klasifikasi per Kelas Sentimen

Kelas	TP	FP	FN	Precision	Recall	F1-Score
Negatif	95	23	21	0,805	0,819	0,812
Netral	273	41	33	0,869	0,892	0,880
Positif	359	29	39	0,925	0,902	0,913
Accuracy						0,887 (88,7%)
Weighted Avg	-	-	-	0,887	0,887	0,887

Berdasarkan Gambar 4.4 dan Tabel 4.8, model IndoBERT mencapai akurasi keseluruhan sebesar 88,7% dengan performa yang konsisten tinggi di semua kelas sentimen. Kelas Positif mencatat performa terbaik dengan Precision 0,925, Recall

0,902, dan F1-Score 0,913. Tingginya performa pada kelas ini didukung oleh jumlah data training yang paling besar (2.549 sampel), sehingga model memiliki cukup contoh untuk mempelajari pola komentar positif secara mendalam.


Kelas Netral menunjukkan performa yang baik dengan Precision 0,869, Recall 0,892, dan F1-Score 0,880. IndoBERT mampu membedakan komentar netral yang umumnya berupa pertanyaan atau pernyataan informatif dari komentar positif maupun negatif dengan cukup akurat.

Kelas Negatif mencatat Precision 0,805, Recall 0,819, dan F1-Score 0,812 yang meskipun merupakan nilai terendah di antara ketiga kelas, tetap jauh lebih tinggi dibandingkan SVM (0,605). Peningkatan sebesar 34% ini menunjukkan bahwa kemampuan IndoBERT memahami konteks kalimat secara bidireksional sangat membantu dalam menangkap nuansa keluhan dan bahasa informal yang kompleks dalam komentar YouTube (Wilie, et al., 2020).

4.6 Perbandingan Performa Model SVM dan IndoBERT

Perbandingan performa antara model SVM dan IndoBERT dilakukan berdasarkan empat metrik evaluasi standar dalam klasifikasi teks, yaitu: akurasi (accuracy), presisi (precision), recall, dan F1-Score (weighted average).

Perbandingan ditampilkan secara visual pada Gambar 4.5 dan secara numerik pada Tabel 4.9.



Gambar 4. 6 Perbandingan Performa Model SVM dan IndoBERT

Tabel 4. 9 Perbandingan Metrik Evaluasi SVM dan IndoBERT

Metrik Evaluasi	SVM	IndoBERT	Selisih	Peningkatan (%)
Accuracy	0,776 (77,6%)	0,887 (88,7%)	+0,111	+14,3%
Precision (Weighted Avg)	0,774 (77,4%)	0,887 (88,7%)	+0,113	+14,6%
Recall (Weighted Avg)	0,776 (77,6%)	0,887 (88,7%)	+0,111	+14,3%
F1-Score (Weighted Avg)	0,774 (77,4%)	0,887 (88,7%)	+0,113	+14,6%

Berdasarkan Tabel 4.9, model IndoBERT secara konsisten mengungguli SVM pada semua metrik evaluasi dengan peningkatan sekitar 14%. IndoBERT mencapai akurasi 88,7% dibandingkan SVM yang hanya 77,6%. Keunggulan

IndoBERT dapat dijelaskan oleh tiga faktor utama. Pertama, IndoBERT telah di-pretrain menggunakan miliaran token teks Bahasa Indonesia, sehingga memiliki representasi linguistik yang jauh lebih kaya dibandingkan pendekatan CountVectorizer pada SVM. Kedua, mekanisme self-attention dalam arsitektur Transformer memungkinkan IndoBERT menangkap hubungan antar kata dalam jarak jauh dalam sebuah kalimat. Ketiga, fine-tuning memungkinkan model untuk beradaptasi secara spesifik dengan karakteristik komentar YouTube Indonesia (Wilie, et al., 2020).

Meski demikian, perlu diperhatikan bahwa IndoBERT membutuhkan sumber daya komputasi yang jauh lebih besar. Proses training IndoBERT memerlukan GPU dan waktu beberapa jam, sedangkan SVM hanya membutuhkan CPU biasa dengan waktu training beberapa menit. Untuk skenario dengan sumber daya komputasi terbatas atau kebutuhan inferensi real-time, SVM dengan akurasi 77,6% tetap merupakan pilihan yang viable.

4.7 Analisis Sentimen Berbasis Aspek (ABSA)

Analisis Sentimen Berbasis Aspek (ABSA) dilakukan dengan mengombinasikan dua hasil klasifikasi secara bersamaan pada setiap komentar: (1) label sentimen (Positif/Netral/Negatif) yang dihasilkan oleh model IndoBERT, dan (2) label aspek (salah satu dari 6 kategori) yang dihasilkan oleh pendekatan rule-based keyword matching. Pendekatan mengombinasikan dua modul terpisah untuk ekstraksi aspek dan klasifikasi sentimen ini sejalan dengan arsitektur ABSA yang umum digunakan dalam penelitian terkini (Puvvula & Rodda, 2024). Kombinasi keduanya memungkinkan setiap komentar memiliki profil opini yang lebih spesifik dibandingkan analisis sentimen konvensional, sesuai dengan konsep dasar ABSA.

Tabel 4. 10 Contoh hasil ABSA pada komentar aktual dari dataset

Komentar	Aspek Teridentifikasi	Sentimen
"Syarat 4.000 jam tayang terlalu berat bagi pemula"	Syarat & Kebijakan Monetisasi	Negatif
"Makasih bang, kontennya sangat bermanfaat dan mudah dipahami"	Apresiasi Konten Edukasi	Positif
"Cara daftar YPP bagaimana ya, subscriber saya sudah 1000"	Syarat & Kebijakan Monetisasi	Netral
"Channel saya sepi penonton padahal sudah upload rutin"	Channel & Performa Konten	Negatif
"Semangat terus bang, nanti pasti bisa monetisasi!"	Dukungan Komunitas & Semangat	Positif

Hasil kombinasi seluruh 5.464 komentar dirangkum pada tabel 4.11 berikut:

Tabel 4. 11 Distribusi Sentimen per Aspek

Aspek	Positif	Netral	Negatif	Total
Dukungan Komunitas & Semangat	925 (57,4%)	492 (30,5%)	194 (12,0%)	1.611
Syarat & Kebijakan Monetisasi	282 (24,7%)	557 (48,8%)	302 (26,5%)	1.141
Apresiasi Konten Edukasi	823 (77,3%)	181 (17,0%)	60 (5,6%)	1.064
Channel & Performa Konten	320 (31,4%)	443 (43,4%)	257 (25,2%)	1.020
Engagement Penonton	120 (35,8%)	141 (42,1%)	74 (22,1%)	335
Bantuan Teknis & Akun	79 (27,0%)	141 (48,1%)	73 (24,9%)	293

Total	2.549 (46,6%)	1.955 (35,8%)	960 (17,6%)	5.464
-------	------------------	------------------	-------------	-------

Berdasarkan Tabel 4.11, beberapa temuan penting dapat diuraikan per aspek sebagai berikut:

1. Aspek Dukungan Komunitas & Semangat merupakan aspek dengan jumlah komentar terbanyak (1.611 komentar, 29,48%) dan didominasi sentimen positif (57,4%). Hal ini mencerminkan budaya komunitas kreator YouTube Indonesia yang aktif saling memberikan motivasi dan semangat satu sama lain dalam perjalanan menuju monetisasi.
2. Aspek Apresiasi Konten Edukasi mencatat sentimen positif tertinggi di antara semua aspek (77,3% dari 1.064 komentar). Temuan ini menunjukkan bahwa penonton sangat menghargai konten video yang memberikan panduan praktis tentang cara memenuhi syarat monetisasi YPP.
3. Aspek Syarat & Kebijakan Monetisasi mencatat sentimen negatif tertinggi di antara semua aspek (26,5% dari 1.141 komentar). Ini mengindikasikan bahwa persyaratan YPP khususnya minimal 1.000 subscriber dan 4.000 jam watch time masih dipandang berat oleh kreator pemula Indonesia.
4. Aspek Channel & Performa Konten memiliki sentimen negatif sebesar 25,2% dari 1.020 komentar. Banyak kreator mengungkapkan frustrasi terkait performa channel mereka yang stagnan meski sudah rutin mengunggah konten, menunjukkan bahwa algoritma YouTube masih menjadi tantangan yang belum terpahami sepenuhnya.
5. Aspek Bantuan Teknis & Akun meskipun memiliki jumlah komentar terendah (293 komentar, 5,36%), mencatat sentimen negatif sebesar 24,9%. Proporsi negatif yang cukup tinggi ini mengindikasikan bahwa kreator yang mengalami masalah teknis cenderung merasa tidak mendapat dukungan yang memadai dari platform.
6. Aspek Engagement Penonton menunjukkan distribusi yang relatif seimbang antara netral (42,1%) dan positif (35,8%) dengan sentimen negatif 22,1% dari 335 komentar. Aspek ini mencerminkan kekhawatiran kreator terhadap minimnya interaksi penonton pada konten mereka.

Secara keseluruhan, dominasi sentimen positif (46,6%) mengindikasikan bahwa komunitas kreator YouTube Indonesia bersikap optimis terhadap ekosistem monetisasi, meskipun terdapat frustrasi yang nyata pada aspek kebijakan dan dukungan teknis platform (Firdaus & Trisnawarman, 2025).