



Klasifikasi Teks Komentar Penggunaan Listrik Gratis di Youtube Menggunakan Metode Naïve Bayes

Mikho Alfatih Harahap*, Abdul Halim Hasugian

Fakultas Sains dan Teknologi, Program Studi Ilmu Komputer, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia

Email: ^{1*}mikoalfatihharahap@gmail.com, ²abdulhalimhasugian@uinsu.ac.id

Email Penulis Korespondensi: mikoalfatihharahap@gmail.com

Abstrak—Perkembangan media sosial menjadikan YouTube sebagai salah satu sarana masyarakat dalam menyampaikan opini terhadap kebijakan pemerintah, termasuk program penggunaan listrik gratis. Banyaknya komentar yang masuk menyebabkan proses analisis secara manual menjadi sulit dilakukan, sehingga dibutuhkan metode klasifikasi teks yang mampu mengelompokkan komentar secara otomatis. Penelitian ini bertujuan untuk mengklasifikasikan komentar pengguna YouTube terkait program listrik gratis menggunakan algoritma Naïve Bayes. Data penelitian diperoleh melalui proses crawling komentar pada sepuluh video YouTube yang membahas kebijakan listrik gratis, sehingga diperoleh 910 komentar dan setelah proses pembersihan data menjadi 906 komentar. Tahapan pengolahan data meliputi cleaning, case folding, tokenizing, normalisasi, stopword removal, stemming, serta pembobotan kata menggunakan TF-IDF. Selanjutnya data diklasifikasikan ke dalam empat kategori, yaitu Diskusi dan Informasi Publik, Dukungan dan Apresiasi Kebijakan, Keluhan dan Kendala Teknis, serta Non-Listrik. Evaluasi model dilakukan menggunakan confusion matrix dengan metrik akurasi, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa algoritma Naïve Bayes mampu memberikan performa klasifikasi yang cukup baik dengan akurasi sebesar 70,9%, precision 0,62, recall 0,80, dan F1-score 0,70. Kategori Non-Listrik memperoleh performa terbaik dengan precision 0,77, recall 0,90, dan F1-score 0,83. Berdasarkan hasil tersebut, metode Naïve Bayes dinilai efektif untuk klasifikasi opini publik pada data komentar media sosial.

Kata Kunci: Klasifikasi Teks; YouTube; Naïve Bayes; TF-IDF; Analisis Komentar

Abstract—The growth of social media has made YouTube one of the platforms used by the public to express opinions regarding government policies, including the free electricity program. The large number of comments makes manual analysis difficult; therefore, a text classification method is needed to automatically categorize comments. This study aims to classify YouTube user comments related to the free electricity program using the Naïve Bayes algorithm. The research data were obtained through a crawling process from ten YouTube videos discussing the free electricity policy, resulting in 910 comments, which were reduced to 906 comments after data cleaning. The data processing stages included cleaning, case folding, tokenizing, normalization, stopword removal, stemming, and term weighting using TF-IDF. Furthermore, the data were classified into four categories: Public Discussion and Information, Policy Support and Appreciation, Complaints and Technical Issues, and Non-Electricity. Model evaluation was conducted using a confusion matrix with accuracy, precision, recall, and F1-score metrics. The results showed that the Naïve Bayes algorithm provided fairly good classification performance with an accuracy of 70.9%, precision of 0.62, recall of 0.80, and F1-score of 0.70. The Non-Electricity category achieved the best performance with precision of 0.77, recall of 0.90, and F1-score of 0.83. Based on these findings, the Naïve Bayes method is considered effective for classifying public opinion from social media comment data.

Keywords: Text Classification; YouTube; Naïve Bayes; TF-IDF; Comment Analysis

1. PENDAHULUAN

Kemiskinan masih menjadi permasalahan utama di Indonesia yang berdampak pada keterbatasan akses masyarakat terhadap kebutuhan dasar, termasuk energi listrik. Pemerintah telah mengimplementasikan berbagai program bantuan sosial, salah satunya subsidi listrik bagi rumah tangga kurang mampu, sebagai upaya meningkatkan kesejahteraan dan mengurangi beban pengeluaran masyarakat (Alkadri & Insani, 2023). Program ini diharapkan mampu mendukung pemerataan akses energi serta mengurangi kesenjangan sosial. Namun, dalam implementasinya, penyaluran bantuan listrik masih menghadapi berbagai kendala, terutama dalam penentuan kelayakan penerima yang belum sepenuhnya tepat sasaran, sehingga menimbulkan ketidaksesuaian antara kondisi di lapangan dan data penerima bantuan (Rahmansyah et al., 2021).

Perkembangan teknologi informasi dan media sosial turut memengaruhi cara masyarakat menyampaikan opini terhadap kebijakan public (Alfriyanto et al., 2024). Platform seperti YouTube menjadi salah satu media yang banyak digunakan untuk mengekspresikan pendapat melalui komentar pada video yang membahas program pemerintah. Komentar tersebut mengandung berbagai bentuk respons, seperti dukungan, kritik, maupun keluhan terhadap kebijakan listrik gratis. Data komentar ini memiliki potensi besar sebagai sumber informasi untuk memahami persepsi masyarakat, namun bersifat tidak terstruktur dan memiliki volume yang besar sehingga sulit dianalisis secara manual serta berpotensi menimbulkan subjektivitas (Santoso et al., 2023).

Untuk mengatasi permasalahan tersebut, diperlukan pendekatan berbasis teknologi seperti *text mining* yang mampu mengolah data teks secara otomatis dan sistematis. Salah satu teknik dalam *text mining* adalah klasifikasi teks, yaitu proses pengelompokan data ke dalam kategori tertentu berdasarkan karakteristik yang dimiliki (Hendrastuty, 2024). Beberapa penelitian sebelumnya telah menerapkan metode klasifikasi teks untuk analisis opini publik menggunakan berbagai algoritma, seperti *Support Vector Machine*, *K-Nearest Neighbor*, dan *Naïve Bayes* (Mukti et al., 2023). Hasil penelitian menunjukkan bahwa metode klasifikasi mampu membantu dalam memahami pola opini masyarakat secara lebih objektif. Namun (Pebdika et al., 2023), sebagian besar penelitian tersebut masih berfokus pada

objek umum dan belum secara spesifik membahas analisis opini terhadap program listrik gratis, serta belum memanfaatkan data komentar YouTube secara optimal sebagai sumber analisis (Darwis et al., 2021).

Beberapa penelitian terdahulu telah dilakukan terkait klasifikasi teks dan analisis sentimen pada media sosial. Darwis et al. (2021) menerapkan algoritma *Naïve Bayes* untuk analisis sentimen data Twitter dan menunjukkan hasil klasifikasi yang cukup baik dalam mengelompokkan opini publik. Putri et al. (2023) menggunakan *Naïve Bayes* untuk menganalisis ulasan produk dan berhasil mengklasifikasikan opini pengguna dengan tingkat akurasi yang baik. Mukti et al. (2023) juga mengembangkan sistem analisis sentimen berbasis web menggunakan teknik *Natural Language Processing* (NLP) untuk memahami persepsi masyarakat terhadap isu publik, yang menunjukkan bahwa klasifikasi teks mampu memberikan informasi yang lebih objektif (Afifa et al., 2023).

Meskipun demikian, penelitian-penelitian tersebut umumnya menggunakan data dari platform seperti Twitter atau ulasan produk, serta hanya berfokus pada klasifikasi sentimen positif dan negatif. Pemanfaatan data komentar YouTube sebagai sumber analisis opini publik masih terbatas, khususnya dalam konteks kebijakan pemerintah seperti program listrik gratis. Selain itu, belum banyak penelitian yang mengelompokkan komentar ke dalam kategori yang lebih spesifik seperti dukungan kebijakan, keluhan teknis, dan diskusi publik. Hal ini menunjukkan adanya kesenjangan penelitian yang perlu dikaji lebih lanjut (Hasibuan & Suhardi, 2022).

Berdasarkan hal tersebut, penelitian ini mengusulkan penerapan algoritma *Naïve Bayes* untuk mengklasifikasikan komentar masyarakat terkait program listrik gratis. Metode ini dipilih karena memiliki keunggulan dalam hal kesederhanaan, kecepatan proses, serta kemampuan menghasilkan akurasi yang baik dalam pengolahan data teks. Selain itu, *Naïve Bayes* juga mampu bekerja secara efektif pada data dalam jumlah besar dan tidak terstruktur, sehingga sesuai untuk menganalisis komentar dari media sosial (Insan et al., 2023).

Kontribusi utama dari penelitian ini adalah pemanfaatan data komentar YouTube sebagai sumber analisis opini publik terhadap kebijakan listrik gratis serta penerapan metode klasifikasi berbasis *Naïve Bayes* untuk menghasilkan informasi yang lebih objektif dan terukur. Hasil penelitian ini diharapkan dapat memberikan gambaran yang lebih jelas mengenai persepsi masyarakat serta menjadi bahan evaluasi bagi pihak terkait dalam meningkatkan ketepatan sasaran program bantuan sosial.


2. METODOLOGI PENELITIAN

2.1 Kerangka Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen yang bertujuan untuk mengklasifikasikan teks komentar pengguna YouTube terkait penggunaan listrik gratis menggunakan algoritma *Naïve Bayes*. Pendekatan kuantitatif dipilih karena penelitian ini berfokus pada pengolahan data numerik hasil transformasi teks serta pengukuran performa model klasifikasi secara objektif menggunakan metrik evaluasi (Septianingrum & Irawan, 2021). Metode eksperimen digunakan untuk menguji kinerja algoritma dalam mengklasifikasikan data berdasarkan pola yang dipelajari dari data latih dan diuji menggunakan data uji (Mukti et al., 2023).

Objek penelitian berupa komentar pengguna YouTube yang berkaitan dengan kebijakan listrik gratis. Data yang digunakan merupakan data sekunder yang diperoleh melalui proses pengambilan data dari platform YouTube. Penelitian ini tidak melibatkan responden secara langsung, melainkan menggunakan data teks sebagai sumber utama analisis. Variabel dalam penelitian ini terdiri dari variabel input berupa teks komentar dan variabel output berupa kelas sentimen, yaitu positif dan negative (Saripah & Sibarani, 2024). Teknik analisis yang digunakan meliputi *text mining*, pembobotan fitur menggunakan TF-IDF, serta klasifikasi menggunakan algoritma *Multinomial Naïve Bayes* (Mahiddin et al., 2022).

Kerangka pemikiran penelitian ini mencakup tahapan mulai dari perencanaan, pengumpulan data, *pre-processing*, klasifikasi, hingga evaluasi hasil. Setiap tahapan dilakukan secara sistematis untuk memastikan bahwa proses klasifikasi berjalan secara optimal dan menghasilkan model yang akurat dalam mengelompokkan opini masyarakat (Pratama & Ikhwan, 2023).



Gambar 1. Kerangka Kerja Penelitian

2.2 Tahapan Penelitian

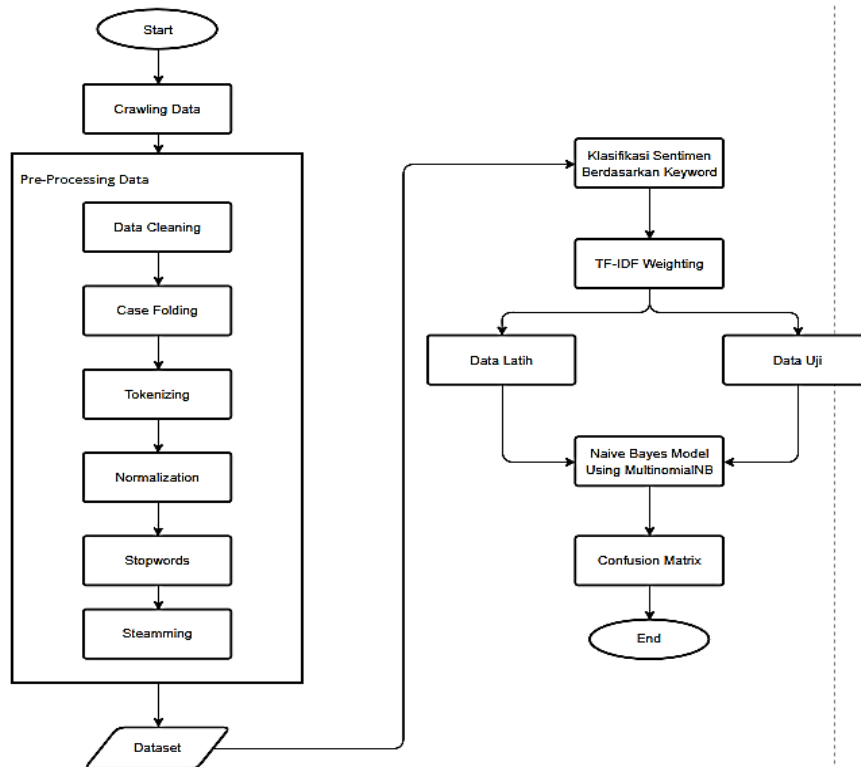
Tahapan penelitian dimulai dari proses perencanaan, yaitu dengan mengidentifikasi permasalahan terkait beragamnya opini masyarakat terhadap kebijakan penggunaan listrik gratis yang disampaikan melalui komentar pada platform YouTube. Pada tahap ini juga ditentukan tujuan penelitian, metode yang digunakan, serta perancangan alur penelitian secara sistematis agar sesuai dengan tujuan yang telah ditetapkan.

Secara keseluruhan, tahapan penelitian ini dapat dilihat pada Gambar 1 yang menggambarkan kerangka kerja penelitian mulai dari tahap perencanaan hingga evaluasi hasil.

Tahap selanjutnya adalah pengumpulan data yang dilakukan dengan teknik *web scraping* atau pemanfaatan *Application Programming Interface (API)* YouTube untuk memperoleh komentar yang relevan dengan topik penelitian. Data yang diperoleh berupa data sekunder yang tidak terstruktur, terdiri dari berbagai opini, kritik, dan dukungan masyarakat. Dataset yang dikumpulkan kemudian diseleksi untuk memastikan relevansi serta menghilangkan data duplikat atau tidak bermakna (Darwis et al., 2021).

Setelah data terkumpul, dilakukan tahap *pre-processing* untuk membersihkan dan menyiapkan data teks. Proses ini meliputi *case folding*, *tokenizing*, *stopword removal*, dan *stemming* untuk mengubah teks menjadi bentuk yang lebih terstruktur dan siap dianalisis (Prasetya et al., 2024). Tahapan ini sangat penting karena kualitas data sangat memengaruhi hasil klasifikasi (Heliyanti Susana, 2022).

Alur proses metode secara lebih rinci ditunjukkan pada Gambar 2, yaitu flowchart metode *Naïve Bayes* yang menggambarkan tahapan mulai dari *crawling data*, *pre-processing*, pelabelan data, pembobotan TF-IDF, hingga proses klasifikasi dan evaluasi.



Gambar 2. Flowchart Metode *Naïve Bayes*

Selanjutnya, dilakukan proses pelabelan data menggunakan pendekatan berbasis *keyword* untuk menentukan kelas sentimen komentar. Data yang telah diberi label kemudian diubah ke dalam bentuk numerik menggunakan metode TF-IDF untuk memberikan bobot pada setiap kata berdasarkan tingkat kepentingannya dalam dokumen.

Tahap berikutnya adalah pembagian data menjadi data latih dan data uji. Data latih digunakan untuk membangun model klasifikasi menggunakan algoritma *Multinomial Naïve Bayes*, sedangkan data uji digunakan untuk menguji performa model dalam mengklasifikasikan komentar baru (Putri et al., 2023).

Tahap akhir adalah evaluasi hasil menggunakan *Confusion Matrix* untuk memperoleh nilai akurasi, precision, recall, dan F1-score. Hasil evaluasi ini digunakan untuk menilai kinerja model dalam mengklasifikasikan komentar YouTube secara tepat dan konsisten (Anggrawan et al., 2021). Berdasarkan hasil tersebut, kemudian dilakukan penarikan kesimpulan sebagai jawaban atas tujuan penelitian.

2.3 Algoritma *Naïve Bayes*

Algoritma *Naïve Bayes* merupakan salah satu metode klasifikasi berbasis probabilitas yang didasarkan pada Teorema Bayes dengan asumsi independensi antar fitur. Metode ini menghitung probabilitas suatu data termasuk ke dalam kelas tertentu berdasarkan peluang kemunculan fitur-fitur yang dimiliki data tersebut (Sihombing, 2021). Secara umum, persamaan dasar *Naïve Bayes* adalah sebagai berikut:

$$P(C|X) = \frac{P(X|C).P(C)}{P(X)} \tag{1}$$



Dimana $P(C|X)$ merupakan probabilitas posterior, $P(X|C)$ adalah likelihood, $P(C)$ adalah prior probability, dan $P(X)$ adalah evidence. Dalam konteks klasifikasi teks, X merepresentasikan kumpulan kata dalam dokumen, sedangkan C merupakan kelas kategori (Mokoagow & Purnomo, 2024).

Pada penelitian ini digunakan metode Multinomial Naïve Bayes yang umum digunakan dalam klasifikasi teks. Metode ini bekerja dengan menghitung frekuensi kemunculan kata dalam setiap kelas dan menentukan kelas dengan probabilitas tertinggi sebagai hasil klasifikasi. Untuk menghindari nilai probabilitas nol akibat kata yang tidak muncul dalam data latih, digunakan teknik Laplace Smoothing. Dengan demikian, setiap kata tetap memiliki peluang kemunculan meskipun tidak terdapat dalam suatu kelas tertentu. Algoritma Naïve Bayes dipilih karena memiliki keunggulan dalam kesederhanaan perhitungan, efisiensi komputasi, serta kemampuan yang baik dalam mengolah data teks dalam jumlah besar.

2.4 Objek Penelitian

Objek dalam penelitian ini adalah komentar pengguna pada platform YouTube yang membahas kebijakan penggunaan listrik gratis di Indonesia. Data yang digunakan merupakan data sekunder yang diperoleh melalui proses crawling menggunakan YouTube Data API v3. Komentar yang dikumpulkan berasal dari sepuluh video YouTube yang relevan dengan topik penelitian. Dataset awal berjumlah 910 komentar, yang kemudian melalui proses pembersihan data (*cleaning*) sehingga diperoleh sebanyak 906 komentar yang siap dianalisis.

Data komentar tersebut memiliki karakteristik tidak terstruktur, mengandung bahasa informal, serta beragam opini masyarakat seperti dukungan, kritik, dan pertanyaan. Oleh karena itu, data ini sangat sesuai digunakan dalam penelitian klasifikasi teks untuk menganalisis persepsi publik terhadap kebijakan pemerintah. Variabel dalam penelitian ini terdiri dari:

1. Variabel input: teks komentar pengguna YouTube
2. Variabel output: kategori komentar, yaitu:
 - a. Dukungan dan Apresiasi Kebijakan
 - b. Keluhan dan Kendala Teknis
 - c. Diskusi dan Informasi Publik
 - d. Non-Listrik

Dengan objek penelitian tersebut, diharapkan hasil klasifikasi dapat memberikan gambaran yang lebih jelas mengenai persepsi masyarakat terhadap program listrik gratis

3. HASIL DAN PEMBAHASAN

Pada bagian ini membahas hasil penelitian yang telah dilakukan dalam mengklasifikasikan teks komentar pengguna terkait program listrik gratis pada platform YouTube menggunakan algoritma Naïve Bayes. Penelitian ini bertujuan untuk mengelompokkan komentar pengguna berdasarkan respons dan persepsi publik terhadap kebijakan listrik gratis yang dicanangkan pemerintah, khususnya yang disampaikan melalui kolom komentar video YouTube. Proses analisis dilakukan melalui beberapa tahapan utama, yaitu pengumpulan data komentar (*data crawling*), preprocessing teks, pelabelan kategori komentar, pembobotan kata menggunakan metode TF-IDF, serta proses klasifikasi menggunakan algoritma Naïve Bayes. Seluruh tahapan tersebut diimplementasikan menggunakan bahasa pemrograman Python.

Secara umum, hasil penelitian menunjukkan bahwa algoritma Naïve Bayes mampu digunakan secara efektif dalam mengklasifikasikan komentar YouTube terkait penggunaan listrik gratis ke dalam beberapa kategori yang telah ditentukan. Proses klasifikasi ini memberikan gambaran mengenai kecenderungan opini masyarakat, baik dalam bentuk dukungan terhadap kebijakan, keluhan terhadap kendala teknis, maupun diskusi dan pertanyaan publik terkait pelaksanaan program listrik gratis. Dengan demikian, hasil penelitian ini diharapkan dapat menjadi sumber informasi bagi pihak terkait, seperti pemerintah dan penyedia layanan listrik, dalam mengevaluasi serta meningkatkan kualitas pelayanan dan sosialisasi kebijakan listrik kepada Masyarakat.

3.1 Analisis Data

Data dalam penelitian ini diperoleh dari komentar pengguna YouTube pada sepuluh video yang membahas kebijakan listrik gratis. Pengumpulan data dilakukan menggunakan YouTube Data API v3 dengan bantuan Python, sehingga diperoleh sebanyak 910 komentar yang disimpan dalam format *.csv*. Setelah dilakukan proses *data cleaning* untuk menghapus komentar duplikat dan tidak relevan, jumlah data yang digunakan menjadi 906 komentar.

Selanjutnya, dilakukan tahap *preprocessing* teks yang meliputi *case folding*, penghapusan karakter tidak relevan, *tokenizing*, normalisasi kata tidak baku, *stopword removal*, dan *stemming* menggunakan Sastrawi. Tahapan ini bertujuan untuk menghasilkan data teks yang bersih dan terstruktur sehingga siap digunakan dalam proses analisis.

Setelah preprocessing, data diberi label sentimen menggunakan pendekatan berbasis kata kunci (*rule-based*). Data yang telah dilabeli kemudian digunakan dalam proses klasifikasi menggunakan algoritma *Naïve Bayes*. Selain itu, data juga divisualisasikan dalam bentuk grafik distribusi dan *wordcloud* untuk menggambarkan kecenderungan opini masyarakat terhadap program listrik gratis.



3.2 Representasi Data

Data yang digunakan dalam penelitian ini diperoleh melalui proses crawling komentar pengguna YouTube pada sepuluh video yang membahas kebijakan listrik gratis. Pengambilan data dilakukan menggunakan YouTube Data API v3 dengan bantuan bahasa pemrograman Python pada Google Colaboratory, sehingga diperoleh sebanyak 910 komentar sebagai dataset awal.

Proses crawling dilakukan menggunakan library `googleapiclient.discovery` dengan memanfaatkan API key serta parameter seperti video ID, jumlah komentar, dan format teks. Pengambilan data dilakukan secara bertahap menggunakan teknik pagination untuk memastikan seluruh komentar dapat dikumpulkan secara optimal. Setiap komentar yang diperoleh diekstraksi ke dalam beberapa atribut, yaitu username, isi komentar, jumlah like, dan waktu publikasi.

3.3 Text Pre-processing

Text pre-processing merupakan tahapan penting dalam penelitian ini yang bertujuan untuk membersihkan dan menyiapkan data teks komentar YouTube agar dapat diolah secara optimal oleh algoritma klasifikasi. Mengingat data komentar di media sosial umumnya bersifat tidak terstruktur, mengandung bahasa tidak formal, serta banyak elemen yang tidak relevan, maka diperlukan serangkaian proses untuk meningkatkan kualitas data sebelum dilakukan pembobotan dan klasifikasi. Tahapan text pre-processing pada penelitian ini meliputi cleaning dan case folding, tokenisasi, normalisasi kata, stopword removal, stemming, serta detokenisasi.

3.3.1 Cleaning dan Case Folding

Cleaning dan case folding merupakan tahap awal dalam proses text pre-processing yang bertujuan untuk membersihkan teks komentar dari karakter dan elemen yang tidak relevan terhadap proses analisis. Pada tahap ini, seluruh komentar YouTube dibersihkan dari berbagai unsur seperti tautan (URL), simbol, tanda baca, emotikon, karakter khusus, serta angka yang tidak memiliki makna semantik dalam konteks analisis teks. Selain itu, teks juga dibersihkan dari *mention* dan format lain yang sering muncul dalam komentar YouTube. Selanjutnya, dilakukan proses case folding dengan mengubah seluruh huruf dalam teks menjadi huruf kecil (*lowercase*). Proses ini bertujuan untuk menyeragamkan bentuk kata sehingga algoritma tidak membedakan kata yang memiliki makna sama tetapi ditulis dengan kapitalisasi berbeda, seperti “PLN” dan “pln” atau “Listrik” dan “listrik”. Proses cleaning dan case folding dilakukan menggunakan *regular expression* pada bahasa pemrograman Python.

3.3.2 Tokenizing

Tahap tokenisasi dilakukan untuk memecah teks komentar yang telah dibersihkan menjadi unit-unit kata yang lebih kecil, yang disebut token. Proses ini bertujuan agar setiap kata dalam komentar dapat dianalisis secara individual pada tahapan selanjutnya. Tokenisasi dilakukan menggunakan library Natural Language Toolkit (NLTK) dengan fungsi `word_tokenize`. Dengan proses ini, satu kalimat komentar diubah menjadi daftar kata yang terpisah berdasarkan spasi dan tanda pemisah lainnya. Tokenisasi sangat penting dalam pengolahan teks karena memungkinkan sistem untuk mengidentifikasi frekuensi kemunculan kata serta melakukan operasi lanjutan seperti normalisasi, penghapusan stopword, dan stemming. Hasil tokenisasi berupa kumpulan kata dalam bentuk list yang mewakili isi dari setiap komentar YouTube.

3.3.3 Normalization

Normalisasi kata dilakukan untuk mengubah kata tidak baku atau bahasa gaul yang umum digunakan dalam komentar YouTube menjadi kata baku dalam bahasa Indonesia. Komentar pada media sosial sering kali menggunakan singkatan atau istilah informal, seperti “gk”, “ga”, “klo”, atau “bgt”, yang dapat memengaruhi akurasi analisis apabila tidak diseragamkan. Oleh karena itu, pada penelitian ini digunakan kamus slang (`kamusGaul.txt`) sebagai acuan untuk melakukan normalisasi kata. Proses normalisasi dilakukan dengan mencocokkan setiap token kata dengan daftar kata dalam kamus slang, kemudian menggantinya dengan bentuk kata baku yang sesuai. Sebagai contoh, kata “gk” dinormalisasi menjadi “tidak”, dan kata “klo” diubah menjadi “kalau”. Normalisasi ini bertujuan untuk memperkaya representasi teks dan mengurangi variasi kata yang memiliki makna sama.

3.3.4 Stopword Removal

Tahap selanjutnya adalah penghapusan kata berhenti (*stopword removal*), yaitu proses menghilangkan kata-kata umum yang sering muncul dalam teks tetapi tidak memiliki kontribusi signifikan terhadap makna atau klasifikasi komentar. Kata-kata seperti “dan”, “yang”, “di”, “ke”, serta beberapa kata percakapan khas media sosial seperti “nih”, “aj”, “loh”, dan “gaes” termasuk dalam kategori stopword. Daftar stopword yang digunakan pada penelitian ini diperoleh dari library NLTK Bahasa Indonesia dan ditambahkan dengan stopword tambahan yang disesuaikan dengan konteks komentar YouTube. Proses ini bertujuan untuk mengurangi noise pada data dan meningkatkan fokus analisis terhadap kata-kata yang benar-benar merepresentasikan isi dan maksud komentar pengguna.



3.3.5 Stemming

Stemming merupakan proses untuk mengubah kata berimbuhan menjadi bentuk kata dasarnya. Pada penelitian ini, proses stemming dilakukan menggunakan Sastrawi Stemmer, yang dirancang khusus untuk bahasa Indonesia. Tahap ini penting untuk mengurangi variasi kata yang memiliki akar kata sama, sehingga kata seperti “membantu”, “dibantu”, dan “bantuan” dapat direduksi menjadi kata dasar “bantu”. Proses stemming dilakukan setelah stopword removal agar hanya kata-kata yang relevan yang diproses lebih lanjut. Untuk meningkatkan efisiensi komputasi mengingat jumlah data yang cukup besar, proses stemming dioptimalkan dengan bantuan library Swifter. Hasil stemming berupa kumpulan kata dasar yang lebih konsisten dan siap untuk dianalisis pada tahap selanjutnya.

3.3.6 Detokenized Text

Tahap terakhir dalam text pre-processing adalah detokenisasi, yaitu proses penggabungan kembali token kata yang telah melalui tahap stemming menjadi bentuk teks utuh. Detokenisasi dilakukan menggunakan TreebankWordDetokenizer dari NLTK. Proses ini bertujuan untuk menghasilkan teks bersih dalam format kalimat yang dapat digunakan sebagai input pada tahap pembobotan kata menggunakan TF-IDF dan proses klasifikasi menggunakan algoritma Naïve Bayes.

Hasil akhir dari seluruh tahapan text pre-processing ini menghasilkan data komentar YouTube yang telah bersih, terstruktur, dan representatif, yang kemudian disimpan dalam file ListrikgratisText.csv. Data inilah yang selanjutnya digunakan pada tahap ekstraksi fitur dan klasifikasi untuk menganalisis komentar pengguna terkait program listrik gratis.

3.4 Pembobotan Kata Menggunakan TF-IDF

3.4.1 Menghitung Term-Frequency (TF)

Pada tahap ini dilakukan pembobotan kata menggunakan metode TF-IDF (Term Frequency – Inverse Document Frequency) untuk mengetahui tingkat kepentingan suatu kata dalam satu komentar terhadap keseluruhan kumpulan komentar (corpus). Dalam konteks penelitian ini, setiap dokumen merepresentasikan satu komentar pengguna YouTube yang membahas program listrik gratis, seperti dukungan terhadap kebijakan, keluhan teknis, maupun diskusi informasi publik. Nilai Term Frequency (TF) menunjukkan seberapa sering suatu kata muncul dalam satu dokumen, sedangkan Inverse Document Frequency (IDF) menunjukkan tingkat kelangkaan kata tersebut dalam seluruh dokumen. Semakin tinggi nilai TF-IDF, maka semakin besar pengaruh kata tersebut dalam merepresentasikan isi komentar. Berikut adalah contoh 5 komentar yang digunakan untuk ilustrasi perhitungan manual TF-IDF:

- a. D1: listrik gratis sangat membantu masyarakat kecil
- b. D2: token listrik gratis belum masuk sampai sekarang
- c. D3: bagaimana cara daftar listrik gratis dari pln
- d. D4: listrik sering mati meskipun katanya gratis
- e. D5: terima kasih program listrik gratis sangat bermanfaat

Tabel 1. Tabel TF

Kata	D1	D2	D3	D4	D5	DF
listrik	1	1	1	1	1	5
gratis	1	1	1	1	1	5
membantu	1	0	0	0	0	1
masyarakat	1	0	0	0	0	1
kecil	1	0	0	0	0	1
token	0	1	0	0	0	1
belum	0	1	0	0	0	1
masuk	0	1	0	0	0	1
daftar	0	0	1	0	0	1
pln	0	0	1	0	0	1
mati	0	0	0	1	0	1
terima	0	0	0	0	1	1
kasih	0	0	0	0	1	1
bermanfaat	0	0	0	0	1	1

3.4.2 Menghitung IDF

Tahap selanjutnya menghitung nilai IDF menggunakan persamaan :

$$idf_{(t,D)} = \log_{10} \left(\frac{N}{df} \right)$$

Dengan total n sebanyak 5 dokumen, maka hasil perhitungan sebagian kata ditunjukkan pada tabel berikut:

Tabel 2. Perhitungan IDF

No	Kata	DF	Perhitungan IDF	IDF
1	listrik	5	$\log_{10}(5/5)$	0.000
2	gratis	5	$\log_{10}(5/5)$	0.000
3	membantu	1	$\log_{10}(5/1)$	0.699
4	masyarakat	1	$\log_{10}(5/1)$	0.699
5	kecil	1	$\log_{10}(5/1)$	0.699
6	token	1	$\log_{10}(5/1)$	0.699
7	belum	1	$\log_{10}(5/1)$	0.699
8	masuk	1	$\log_{10}(5/1)$	0.699
9	daftar	1	$\log_{10}(5/1)$	0.699
10	pln	1	$\log_{10}(5/1)$	0.699
11	mati	1	$\log_{10}(5/1)$	0.699
12	terima	1	$\log_{10}(5/1)$	0.699
13	kasih	1	$\log_{10}(5/1)$	0.699
14	bermanfaat	1	$\log_{10}(5/1)$	0.699

3.4.3 Menghitung TF-IDF

Setiap kata yang terdapat dalam komentar pengguna di aplikasi YouTube dianalisis menggunakan metode Term Frequency (TF) dan Inverse Document Frequency (IDF). Langkah pertama dilakukan dengan menghitung seberapa sering suatu kata muncul dalam tiap komentar (TF), lalu dilanjutkan dengan perhitungan IDF untuk mengetahui tingkat kepentingan kata tersebut dalam keseluruhan kumpulan data. Nilai akhir TF-IDF diperoleh dari hasil perkalian antara nilai TF dan IDF, yang mencerminkan bobot suatu kata dalam dokumen.

Dokumen 1, memiliki total 6 kata → $TF = 1/6 = 0.166$

Dokumen 2, memiliki total 6 kata → $TF = 1/6 = 0.166$

Dokumen 3, memiliki total 7 kata → $TF = 1/7 = 0.143$

Dokumen 4, memiliki total 6 kata → $TF = 1/6 = 0.166$

Dokumen 5, memiliki total 6 kata → $TF = 1/6 = 0.166$

$$tf - idf_{t,d} = tf_{td} * idf_t$$

a. $tf - idf_{(membantu,D1)} = 0.166 \times 0.699 = 0.116$

b. $tf - idf_{(token,D2)} = 0.166 \times 0.699 = 0.116$

c. $tf - idf_{(daftar,D3)} = 0.143 \times 0.699 = 0.099$

d. $tf - idf_{(mati,D4)} = 0.166 \times 0.699 = 0.116$

e. $tf - idf_{(bermanfaat,D5)} = 0.166 \times 0.699 = 0.116$

Proses perhitungan nilai TF-IDF menunjukkan hasil akhir perhitungan untuk seluruh kata yang telah dirangkum dan disajikan dalam bentuk tabel di bawah ini, guna memberikan gambaran menyeluruh mengenai bobot masing-masing kata dalam analisis.

Tabel 3. TF-IDF

Kata	Dokumen Muncul	TF-IDF
listrik	D1–D5	0.000
gratis	D1–D5	0.000
membantu	D1	0.116
masyarakat	D1	0.116
kecil	D1	0.116
token	D2	0.116
belum	D2	0.116
masuk	D2	0.116
daftar	D3	0.099
pln	D3	0.099
mati	D4	0.116
terima	D5	0.116
kasih	D5	0.116
bermanfaat	D5	0.116

3.5 Penerapan Algoritma Naïve Bayes pada Komentar Penggunaan Listrik Gratis di YouTube

Proses klasifikasi komentar pengguna YouTube terkait program listrik gratis pada penelitian ini dilakukan menggunakan algoritma Multinomial Naïve Bayes. Algoritma ini bekerja dengan menghitung probabilitas kemunculan



kata pada masing-masing kategori berdasarkan data latih yang telah melalui tahap text preprocessing dan pelabelan. Berbeda dengan penelitian analisis sentimen, pada penelitian ini algoritma Naïve Bayes digunakan untuk mengklasifikasikan komentar ke dalam tiga kategori respons publik, yaitu Dukungan dan Apresiasi Kebijakan, Keluhan dan Kendala Teknis, serta Diskusi dan Informasi Publik.

Untuk menjelaskan cara kerja algoritma secara sistematis, disajikan contoh perhitungan manual menggunakan sejumlah data latih sederhana. Contoh ini bertujuan untuk memperlihatkan bagaimana algoritma Multinomial Naïve Bayes menghitung probabilitas prior, probabilitas kondisional (likelihood), serta probabilitas posterior dalam menentukan kategori suatu komentar.

Tabel 4. Sampel Data Latih

Teks	Kategori
mantap prabowo lanjutkan biar rakyat indonesia makmur sejahtera	Dukungan & Apresiasi Kebijakan
bhong diskon listrik januari pebruari bayar	Keluhan & Kendala Teknis
cara klaim listrik gratisnya gimana ya	Diskusi & Informasi Publik

Setiap komentar pada Tabel 4 diperlakukan sebagai satu dokumen yang terdiri atas kumpulan kata hasil preprocessing. Pada tahap ini, setiap komentar diperlakukan sebagai satu dokumen yang terdiri atas sekumpulan kata hasil proses pembersihan teks. Berdasarkan tiga data latih yang digunakan dalam penelitian ini, jumlah kata pada masing-masing kategori diperoleh sebagai berikut.

- Dukungan & Apresiasi Kebijakan (C1)
mantap, prabowo, lanjutkan, biar, rakyat, indonesia, makmur, sejahtera
→ Total 8 kata
- Keluhan & Kendala Teknis (C2)
bhong, diskon, listrik, januari, pebruari, bayar
→ Total 6 kata
- Diskusi & Informasi Publik (C3)
cara, klaim, listrik, gratisnya, gimana, ya
→ Total 6 kata

Total seluruh kata dari data latih = 20 kata

Jumlah kata unik (vocabulary) = 19 kata

Karena terdapat kemungkinan kata pada data uji tidak muncul pada data latih di suatu kategori, maka digunakan Laplace Smoothing untuk menghindari probabilitas nol.

a. Perhitungan nilai probabilitas

$$P(Kelas | Komentar) = \frac{Jumlah\ Kelas\ X}{Jumlah\ Komentar} \tag{1}$$

Dengan menggunakan persamaan di atas, kita akan memperoleh probabilitas setiap kelas dalam sentimen.

- $P(C1 | Komentar) = \frac{1}{3} = 0.33$
- $P(C2 | Komentar) = \frac{1}{3} = 0.33$
- $P(C3 | Komentar) = \frac{1}{3} = 0.33$

b. Perhitungan Nilai Probabilitas Kondisional (Likelihood) :

Jumlah Kata dan Fitur Unik

- Total kata pada C1 = 8 + 19 = 27 kata
- Total kata pada C2 = 6 + 19 = 25 kata
- Total kata pada C3 = 6 + 19 = 25 kata

Untuk menghindari probabilitas nol pada kata yang tidak muncul di suatu kelas, digunakan teknik Laplace Smoothing, dengan rumus:

$$P(Term | Kelas) = \frac{Frekuensi\ term\ pada\ label + 1}{Total\ Kata\ pada\ label + Jumlah\ fitur\ unik} \tag{2}$$

Dengan menggunakan persamaan di atas, kita akan memperoleh probabilitas suku-suku di setiap kelas sentimen. Untuk kelas C1 (Dukungan & Apresiasi Kebijakan)

- $mantap = (1 + 1)/27 = 2/27 = 0.074$
- $rakyat = (1 + 1)/27 = 2/27 = 0.074$
- $listrik = (0 + 1)/27 = 1/27 = 0.037$
- $gratis = (0 + 1)/27 = 1/27 = 0.037$

Untuk kelas C2 (Keluhan & Kendala Teknis)

- $diskon \rightarrow (1 + 1)/25 = 2/25 = 0.08$
- $bayar \rightarrow (1 + 1)/25 = 2/25 = 0.08$
- $listrik \rightarrow (1 + 1)/25 = 2/25 = 0.08$
- $klaim \rightarrow (0 + 1)/25 = 1/25 = 0.04$

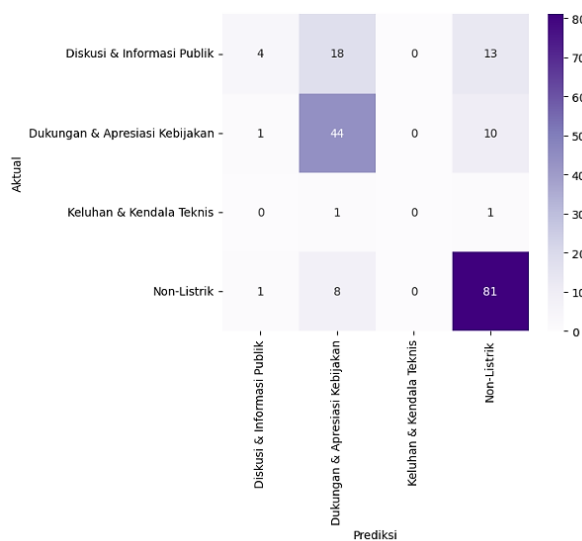


Gambar 4. Wordcloud Keluhan & Kendala Teknis



Gambar 5. Wordcloud Diskusi & Informasi Publik

Setelah dilakukan proses klasifikasi komentar publik menggunakan algoritma Naïve Bayes terhadap isu penggunaan dan kebijakan listrik di media sosial YouTube, tahap selanjutnya adalah melakukan evaluasi performa model menggunakan confusion matrix. Evaluasi ini bertujuan untuk mengetahui sejauh mana model mampu mengklasifikasikan komentar ke dalam empat kategori respons publik, yaitu Diskusi & Informasi Publik, Dukungan & Apresiasi Kebijakan, Keluhan & Kendala Teknis, dan Non-Listrik secara tepat. Data yang digunakan dalam tahap evaluasi ini merupakan data uji yang telah melalui proses text preprocessing dan pembobotan TF-IDF. Hasil prediksi yang dihasilkan oleh model kemudian dibandingkan dengan label aktual untuk mengetahui jumlah prediksi yang benar dan kesalahan klasifikasi pada masing-masing kelas. Confusion matrix memberikan gambaran rinci mengenai distribusi prediksi benar (true positive) dan kesalahan klasifikasi (false positive dan false negative) pada setiap kategori.



Gambar 6. Confusion Matrix Klasifikasi Komentar Listrik YouTube

Berdasarkan confusion matrix yang diperoleh, total data uji yang digunakan dalam evaluasi berjumlah 182 data. Jumlah prediksi yang sesuai dengan label aktual (prediksi benar) adalah 129 data, yang diperoleh dari penjumlahan nilai diagonal utama pada confusion matrix.



$$accuracy = \frac{Total\ Prediksi\ Benar}{Total\ Data} = \frac{4+44681}{182} = \frac{129}{182} = 0.709\ \text{atau}\ 70.9\%$$

$$precision = \frac{TP}{TP + FP} = \frac{44}{44 + 27} = \frac{44}{71} = 0.62\ \text{atau}\ 62\%$$

$$recall = \frac{TP}{TP + FN} = \frac{44}{44 + 11} = \frac{44}{55} = 0.8\ \text{atau}\ 80\%$$

$$F1 - Score = 2 \times \frac{precision \times recall}{precision + recall} = 2 \times \frac{0.62 \times 0.8}{0.62 + 0.8} = 0.7\ \text{atau}\ 70\%$$

Akurasi komentar untuk dataset terdapat pada gambar di bawah ini dimana didapat 0.709, precision yaitu 0.62, recall yaitu 0.8 dan F1-Score yaitu 0.7.

Akurasi Model Kategori Penggunaan Listrik: 70.88%

Classification Report:

	precision	recall	f1-score	support
Diskusi & Informasi Publik	0.67	0.11	0.20	35
Dukungan & Apresiasi Kebijakan	0.62	0.80	0.70	55
Keluhan & Kendala Teknis	0.00	0.00	0.00	2
Non-Listrik	0.77	0.90	0.83	90
accuracy			0.71	182
macro avg	0.51	0.45	0.43	182
weighted avg	0.70	0.71	0.66	182

Gambar 7. Hasil *Confusion Matrix*

Berdasarkan hasil evaluasi confusion matrix, algoritma Naïve Bayes menghasilkan akurasi sebesar 70,9%, yang menunjukkan bahwa sebagian besar komentar berhasil diklasifikasikan sesuai dengan kategori yang benar. Kategori Non-Listrik memiliki performa terbaik dengan nilai precision 0,77, recall 0,90, dan F1-score 0,83, menandakan bahwa model mampu mengenali komentar di luar topik listrik dengan sangat baik.

Kategori Dukungan & Apresiasi Kebijakan juga menunjukkan performa yang cukup baik, terutama pada nilai recall sebesar 0,80, yang menunjukkan bahwa mayoritas komentar dukungan berhasil diidentifikasi oleh model. Namun, nilai precision yang lebih rendah mengindikasikan adanya beberapa komentar dari kategori lain yang salah diklasifikasikan sebagai dukungan kebijakan.

Sementara itu, kategori Diskusi & Informasi Publik memiliki nilai recall yang rendah karena karakteristik bahasanya cenderung mirip dengan komentar dukungan, sehingga sering terjadi kesalahan klasifikasi. Kategori Keluhan & Kendala Teknis tidak berhasil diklasifikasikan dengan baik akibat keterbatasan jumlah data dan kemiripan kosakata dengan kategori lain.

4. KESIMPULAN

Berdasarkan hasil penelitian, klasifikasi komentar publik terkait kebijakan listrik di YouTube berhasil dilakukan menggunakan algoritma *Naïve Bayes*. Data diperoleh melalui proses *web scraping*, kemudian melalui tahapan *pre-processing* yang meliputi *cleaning*, *case folding*, *tokenizing*, *normalization*, *stopword removal*, *stemming*, dan *detokenisasi*. Hasil evaluasi menunjukkan bahwa model mampu mengklasifikasikan komentar ke dalam empat kategori, yaitu Diskusi & Informasi Publik, Dukungan & Apresiasi Kebijakan, Keluhan & Kendala Teknis, dan Non-Listrik dengan tingkat akurasi sebesar 70,9%. Kategori Non-Listrik memiliki performa terbaik dengan nilai precision 0,77, recall 0,90, dan F1-score 0,83. Sementara itu, kategori Dukungan & Apresiasi Kebijakan menunjukkan kinerja yang cukup baik, khususnya pada nilai recall sebesar 0,80. Namun, kategori Diskusi & Informasi Publik serta Keluhan & Kendala Teknis belum optimal diklasifikasikan, yang disebabkan oleh kemiripan karakteristik kata antar kategori serta ketidakseimbangan jumlah data. Secara keseluruhan, algoritma *Naïve Bayes* cukup efektif digunakan untuk klasifikasi opini publik pada data teks media sosial.

REFERENCES

- Afifa, N., Saputra, R. E., & Nugrahaeni, R. A. (2023). Implementasi NLP Pada Chatbot Layanan Akademik Dengan Algoritma Bert. *E-Proceedings of Engineering*, 10(1), 383–387.
- Alfriyanto, N., Purnama, B. C., & Hasanah, F. K. (2024). *Analisis Emosi Terhadap Komentar Video Youtube " Penyebab Kegagalan Adopsi Sistem Pendidikan Finlandia di Indonesia " Menggunakan Metode Random Forest*. 812–827.
- Alkadri, S. P. A., & Insani, R. W. S. (2023). Sistem Pendukung Keputusan Rekomendasi Penerima Bantuan Iuran BPJS Kesehatan Menggunakan Metode ROC dan SMART. *JURNAL FASILKOM*, 13(3), 496–503. <https://doi.org/https://doi.org/10.37859/jf.v13i3.6271>



- Anggrawan, A., Mayadi, M., & Satria, C. (2021). Menentukan Akurasi Tata Letak Barang dengan Menggunakan Algoritma Apriori dan Algoritma FP-Growth. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 21(1), 125–138. <https://doi.org/10.30812/matrik.v21i1.1260>
- Darwis, D., Siskawati, N., & Abidin, Z. (2021). Penerapan Algoritma Naive Bayes Untuk Analisis Sentimen Review Data Twitter Bmkg Nasional. *Jurnal Tekno Kompak*, 15(1), 131. <https://doi.org/10.33365/jtk.v15i1.744>
- Mokoagow, M. A., & Purnomo, A. S. (2024). Penerapan Metode Naive Bayes Pada Sistem Pakar Untuk Mendiagnosis Penyakit Ibu Hamil. 4(2).
- Hasibuan, M. S., & Suhardi. (2022). Analisis Sentimen Kebijakan Vaksin Covid-19 Menggunakan SVM dan C4.5. *Jurnal Teknik Elektro Dan Komputer TRIAC*, 19–21.
- Heliyanti Susana. (2022). Penerapan Model Klasifikasi Metode Naive Bayes Terhadap Penggunaan Akses Internet. *Jurnal Riset Sistem Informasi Dan Teknologi Informasi (JURSISTEKNI)*, 4(1), 1–8. <https://doi.org/10.52005/jursistekni.v4i1.96>
- Hendrastuty, N. (2024). Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Dalam Evaluasi Hasil Pembelajaran Siswa. *Jurnal Ilmiah Informatika Dan Ilmu Komputer (Jima-Ilkom)*, 3(1), 46–56.
- Insan, M. K., Hayati, U., & Nurdyawan, O. (2023). Analisis Sentimen Aplikasi Brimo Pada Ulasan Pengguna Di. *Jurnal Mahasiswa Teknik Informatika*, 7(1), 478–483.
- Mahiddin, N. B., Othman, Z. A., Bakar, A. A., & Rahim, N. A. A. (2022). An Interrelated Decision-Making Model for an Intelligent Decision Support System in Healthcare. *IEEE Access*, 10, 31660–31676. <https://doi.org/10.1109/ACCESS.2022.3160725>
- Mukti, A., Hadiyanti, A. D., Nurlaela, A., & Panjaitan, J. (2023). Sistem Analisa Sentiment Bakal Calon Presiden 2024 Menggunakan Metode NLP Berbasis Web. *Sosied*, 6(1), p-ISSN.
- Pebdika, A., Herdiana, R., & Solihudin, D. (2023). Klasifikasi Menggunakan Metode Naive Bayes Untuk Menentukan Calon Penerima Pip. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), 452–458. <https://doi.org/10.36040/jati.v7i1.6303>
- Prasetya, M., Wulandari, M., & Nikmah, S. A. (2024). Implementasi NLP (Natural Language Processing) Dasar pada Analisis Sentiment Review Spotify. *Stains (Seminar Nasional Teknologi & Sains)*, 3(1), 145–153.
- Pratama, A., & Ikhwan, A. (2023). Perancangan Sistem Informasi Monitoring Opini Publik Diskominfo pada Media Online dengan Metode Rapid Application Development. *Sudo Jurnal Teknik Informatika*, 2(3), 86–95. <https://doi.org/10.56211/sudo.v2i3.264>
- Putri, K. S., Setiawan, I. R., & Pambudi, A. (2023). Analisis Sentimen Terhadap Brand Skincare Lokal Menggunakan Naive Bayes Classifier. *Technologia : Jurnal Ilmiah*, 14(3), 227. <https://doi.org/10.31602/tji.v14i3.11259>
- Rahmansyah, N., Lusinia, S. A., Gema, R. L., & Safira, S. (2021). Peramalam Garis Kemiskinan menggunakan Metode Double Moving Average di Provinsi Sumatera Barat. *Majalah Ilmiah UPI YPTK*, 28, 25–29. <https://doi.org/10.35134/jmi.v28i1.68>
- Santoso, H., Putri, R. A., & Sahbandi, S. (2023). Deteksi Komentar Cyberbullying pada Media Sosial Instagram Menggunakan Algoritma Random Forest. *Jurnal Manajemen Informatika (JAMIKA)*, 13(1), 62–72. <https://doi.org/10.34010/jamika.v13i1.9303>
- Saripah, A. P., & Sibarani, F. H. (2024). Analisis Sentimen Terhadap Aplikasi Maxim Menggunakan Algoritma Random Forest. *Journal of Science and Social Research*, 7(3), 1201–1208. <http://jurnal.goretanpena.com/index.php/JSSR>
- Septianingrum, F., & Irawan, A. S. Y. (2021). Metode Seleksi Fitur Untuk Klasifikasi Sentimen Menggunakan Algoritma Naive Bayes: Sebuah Literature Review. *Jurnal Media Informatika Budidarma*, 5(3), 799. <https://doi.org/10.30865/mib.v5i3.2983>
- Sihombing, J. (2021). Klasifikasi Data Antropometri Individu Menggunakan Algoritma Naive Bayes Classifier. *BIOS : Jurnal Teknologi Informasi Dan Rekayasa Komputer*, 2(1), 1–10. <https://doi.org/10.37148/bios.v2i1.15>