


Analisis Sentimen Isu Redominasi Rupiah Menggunakan *Lexicon Based* dan *Naïve Bayes*

DOI: <http://dx.doi.org/10.35889/jutisi.v15i2.3436>

Creative Commons License 4.0 (CC BY – NC) 

Muhammad Fadli¹, Ival Sanjaya^{2*}, Muhammad Surono³, Ryan Randy Suryono⁴

^{1,2,3,4}Magister Ilmu Komputer, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

¹Ekonomi dan Bisnis, Politeknik Negeri Lampung, Bandar Lampung, Indonesia

*e-mail Corresponding Author: ival_sanjaya@teknokrat.ac.id

Abstract

Rupiah redenomination has resurfaced as a strategic issue in Indonesian monetary policy following the announcement of the roadmap by Minister of Finance Purbaya Yudhi Sadewa in 2025. This study aims to analyze public sentiment towards the redenomination issue through a hybrid approach: lexicon based (LBA) based on InSet Lexicon enriched with 217 contextual phrases (“bunker money”, “DPR ketar-ketir”), combined with Naive Bayes based on TF-IDF representation. The primary dataset of 1,087 public comments from YouTube (Isu_Ekonomi_Redominasi.csv) was processed using Sastrawi (stopword removal and stemming). The results show a dominance of positive sentiment (58.3%), driven by the justice frame narrative (redenomination as a tool for exposing corrupt assets), while negative (24.1%) and neutral (17.6%) sentiment reflect concerns over inflation risks and transition confusion. The MNB model achieved an average accuracy of 86.3% in 10-fold cross-validation. The findings reveal that public support is not merely monetary, but rather an expression of collective aspirations for state transparency and accountability. This research demonstrates the effectiveness of a hybrid lexicon-enhanced approach for domain-specific sentiment analysis in Indonesian, while also providing evidence-based policy insights for inclusive policy design.

Keywords: Public Sentiment; Twitter Media; Naive Bayes; Visualization

Abstrak

Redenominasi rupiah kembali mencuat sebagai isu strategis dalam kebijakan moneter Indonesia pasca pengumuman roadmap oleh Menteri Keuangan Purbaya Yudhi Sadewa pada 2025. Penelitian ini bertujuan menganalisis sentimen masyarakat terhadap isu redenominasi melalui pendekatan *lexicon based* berbasis *InSet Lexicon* yang diperkaya dengan 217 frasa kontekstual (misal: “uang bunker”, “DPR ketar-ketir”), dikombinasikan dengan *Naive Bayes* berbasis representasi TF-IDF. Dataset primer berupa 1.087 komentar publik dari YouTube (Isu_Ekonomi_Redominasi.csv) diproses menggunakan Sastrawi (*stopword removal* dan *stemming*). Hasil menunjukkan dominasi sentimen positif (58,3%), didorong oleh narasi justice frame (redenominasi sebagai alat eksposur aset korupsi), sementara sentimen negatif (24,1%) dan netral (17,6%) mencerminkan kekhawatiran atas risiko inflasi dan kebingungan transisi. Model *Naive Bayes* mencapai akurasi rata-rata 86,3% dalam *10 fold cross validation*. Temuan mengungkap bahwa dukungan publik tidak hanya bersifat teknis moneter, melainkan ekspresi aspirasi kolektif terhadap transparansi dan akuntabilitas negara. Penelitian ini membuktikan bahwa pendekatan *lexicon* efektif untuk analisis sentimen domain spesifik dalam Bahasa Indonesia, sekaligus memberikan *policy insight* berbasis bukti untuk desain kebijakan inklusif.

Kata kunci: Analisis Sentimen; Redominasi Rupiah; Lexicon Based; Naïve Bayes

1. Pendahuluan

Analisis sentimen merupakan teknik *text mining* yang banyak digunakan untuk mengetahui opini publik terhadap suatu isu melalui media sosial. Berbagai pendekatan telah diterapkan, di antaranya metode *lexicon based* dan algoritma klasifikasi seperti *Naïve Bayes* yang terbukti efektif dalam mengklasifikasikan sentimen positif dan negatif pada data teks berbahasa Indonesia [5], [8]. Isu redenominasi rupiah kembali mencuat sebagai wacana strategis dalam diskursus kebijakan moneter Indonesia, terutama sejak Menteri Keuangan Purbaya Yudhi Sadewa menggaungkan

rencana penyederhanaan nilai nominal mata uang dengan memangkas tiga digit nol terakhir, misalnya, Rp1.000 menjadi Rp1, Rp10.000 menjadi Rp10, dan seterusnya. Bukan untuk mengubah daya beli atau nilai riil, melainkan untuk meningkatkan efisiensi transaksi, memperkuat citra rupiah di kancah internasional, dan, yang paling krusial, memicu eksposur terhadap praktik penimbunan uang tunai hasil korupsi yang selama ini “tidak terlihat” dalam sistem perbankan formal; respons publik terhadap wacana ini sangat beragam, sebagaimana tergambar dalam lebih dari 1.100 komentar di platform YouTube yang menjadi dataset primer penelitian ini. Dalam konteks ini, analisis sentimen hadir bukan sekadar alat teknis pemrosesan bahasa alami, melainkan sebagai *policy intelligence instrument* yang memungkinkan pemetaan persepsi publik secara akurat, real time, dan unobtrusive, sehingga menjadi fondasi bagi pengambilan keputusan yang inklusif, responsif, dan berbasis bukti terutama ketika isu yang dibahas sangat sensitif, multidimensi, dan rentan terhadap distorsi narasi oleh kepentingan elit.

Analisis sentimen telah banyak digunakan untuk memahami opini publik terhadap isu sosial dan kebijakan melalui media sosial, seperti Pemilu 2024 yang ditelaah menggunakan *Naive Bayes* dengan *lexicon based* [10], serta respon masyarakat terhadap kebijakan harga minyak goreng [11]. Pendekatan yang diusulkan dalam penelitian ini menggabungkan dua paradigma komplementer yaitu *Lexicon Based Approach (LBA)* dan *Naive Bayes Classifier (NBC)*, yang secara teoretis berlandaskan pada *Framing Theory*. *Framing Theory* menjelaskan bagaimana pilihan leksikon dan konstruksi naratif dalam wacana publik membentuk persepsi terhadap kebijakan dalam dataset ini, terdapat dua master frame dominan yaitu *efficiency frame* (“biar tidak kebanyakan nol”, “lebih ringkas”, “praktis seperti Ringgit Malaysia”) dan *justice frame* (“biar uang koruptor tidak laku”, “tikus keluar dari sarang”, “uang di bunker jadi kertas”), sedangkan *Sentiment Compositionality* menegaskan bahwa sentimen sebuah teks tidak hanya ditentukan oleh keberadaan kata-kata sentimen, tetapi juga oleh konteks pragmatis, modifikasi sintaktis (seperti negasi: “tidak malu-maluin”), dan domain *specific semantics* (misalnya, “kelojotan”, “ketar-ketir”, “mampus” justru berkonotasi positif ketika merujuk pada koruptor). Dua teori ini membenarkan penerapan LBA yang diperkaya secara kontekstual bukan hanya dengan *InSet Lexicon standar*, tetapi juga dengan *custom extension* berupa 217 frasa kunci yang diekstraksi langsung dari dataset (seperti “uang bunker”, “DPR ketar-ketir”, “uang hasil korupsi”), sehingga mampu menangkap *positive negative inversion* yang khas dalam retorika politik ekonomi Indonesia, sementara NBC beroperasi sebagai *statistical backbone* yang memberikan bobot probabilistik berdasarkan distribusi aktual kata dalam korpus, mengatasi keterbatasan LBA dalam menangani ambiguitas dan pola implisit.

Proses analisis dimulai dengan preprocessing teks menggunakan pustaka Sastrawi: *case folding*, pembersihan tanda baca dan angka, *stopword removal*, dan *stemming*, menghasilkan teks bersih yang konsisten. Selanjutnya, sistem LBA menilai setiap komentar berdasarkan keberadaan dan polaritas kata/frasa dalam *lexicon* terkustomisasi, misalnya, komentar “biar uang koruptor jadi kertas sampah” diberi skor positif karena mengandung frasa “uang koruptor” (negatif) yang dimodifikasi oleh “jadi kertas sampah” (konsekuensi positif bagi keadilan); prediksi LBA ini kemudian diverifikasi dan dikoreksi oleh NBC, yang dilatih menggunakan representasi TF-IDF dari teks bersih, dengan pelabelan awal otomatis berbasis LBA sebagai pseudo label; model NBC (dengan parameter $\alpha = 0.1$ untuk *smoothing*) menghasilkan probabilitas sentimen untuk setiap kelas, dan keputusan akhir ditetapkan berdasarkan kombinasi *confidence score* dan *semantic consistency* antara kedua pendekatan jika terjadi *mismatch*, kasus tersebut dikategorikan sebagai *edge case* (misalnya, sindiran atau *mixed sentiment*) dan disisihkan untuk manual *review*, proses ini diuji melalui *10 fold cross validation*. Indikasi utama dari temuan penelitian ini adalah bahwa dukungan publik terhadap redenominasi bukanlah respons terhadap pertimbangan teknis moneter semata, melainkan ekspresi aspirasi kolektif terhadap restorasi keadilan ekonomi dan transparansi institusional; dominasi frasa-frasa seperti “uang di bunker”, “DPR tidak setuju”, “uang hasil korupsi”, dan “biar ketahuan” dalam komentar bernada positif mengungkap bahwa masyarakat memandang redenominasi sebagai mekanisme *accountability* yang elegan, bukan melalui penindakan represif, melainkan melalui rekayasa insentif yang memaksa aset gelap masuk ke dalam sistem yang terverifikasi; temuan ini mengarah pada dua rekomendasi kebijakan strategis: pertama, timing pelaksanaan redenominasi harus mempertimbangkan *window of opportunity* politik, di mana dukungan publik sedang tinggi dan tekanan terhadap rezim korup sedang menguat penundaan berkepanjangan (misalnya hingga 2027, seperti yang disebut dalam beberapa komentar) justru memberi ruang bagi aktor korup untuk mengalihkan aset mereka ke bentuk non tunai (emas, properti, mata uang asing); kedua, strategi komunikasi publik harus secara eksplisit memperkuat

justice frame, bukan hanya efficiency frame, karena data menunjukkan bahwa narasi anti-korupsi jauh lebih resonan dan memobilisasi dukungan lintas kelas social.

Lebih jauh lagi, keberadaan *edge cases* yang signifikan (12% dari dataset) yaitu komentar yang mengandung sindiran (“baru rencana udah koar-koar”), skeptisisme berbasis pengalaman historis (“dulu Sanering malah hiperinflasi”), atau kekhawatiran spesifik tentang kelompok rentan (“bagaimana nasib uang Rp500?”) menjadi sinyal dini akan potensi backlash dan kebutuhan akan mitigasi risiko yang lebih granular, termasuk edukasi berbasis komunitas, perlindungan harga sembako selama masa transisi, dan pengembangan pecahan sen untuk menghindari inflasi mikro akibat pembulatan harga; dengan demikian, analisis sentimen bukan hanya memetakan “apa yang dipikirkan rakyat”, tetapi juga membimbing “bagaimana negara harus bertindak” dalam menjalankan reformasi yang berisiko tinggi namun berdampak transformatif.

2. Tinjauan Pustaka

Penelitian sebelumnya menunjukkan bahwa kombinasi metode *lexicon based* dan Naïve Bayes mampu meningkatkan akurasi analisis sentimen. Fahmi et al. menerapkan pendekatan tersebut untuk menganalisis sentimen masyarakat terhadap vaksinasi COVID-19 dan memperoleh hasil klasifikasi yang cukup baik [5]. Penelitian serupa oleh Putra dan Sari [1] menerapkan Multinomial Naive Bayes (MNB) berbasis TF-IDF pada dataset Twitter isu BBM 2022 mencatat presisi 81,5% namun *recall* rendah (74,8%) pada kelas netral mengindikasikan keterbatasan MNB dalam menangkap nuansa halus tanpa *semantic anchoring* dari *lexicon*. Penelitian ini menjawab kelemahan tersebut dengan memadukan MNB dan LBA secara *complementary*, bukan sekadar *pipeline*.

Pendekatan serupa juga digunakan dalam analisis sentimen kebijakan publik, seperti respon masyarakat terhadap pemerintah dan kebijakan pendidikan, yang menunjukkan bahwa Naïve Bayes efektif dalam menangani data teks media sosial [6] [7]. Isu moneter secara khusus juga telah diteliti melalui lensa sentimen. Darmawan et al. [2] menganalisis sentimen publik terhadap kebijakan digitalisasi BI-FAST menggunakan BERT-ID dan menemukan bahwa narasi *financial inclusion* lebih dominan daripada kekhawatiran keamanan. Namun, studi ini bergantung penuh pada *deep learning* tanpa transparansi fitur sehingga tidak memungkinkan *policy insight* berbasis kata kunci. Sebaliknya, studi oleh Kurniawan et al. [6] menggunakan *rule based lexicon* untuk mengukur persepsi inflasi di media sosial selama 2020–2022 dan menemukan korelasi signifikan antara lonjakan sentimen negatif dan kenaikan harga pangan ($\rho = 0.72$, $p < 0.01$), membuktikan nilai analisis sentimen sebagai *leading indicator* kebijakan. Penelitian ini memperluas temuan tersebut ke isu struktural (redenominasi) dengan skala dan kompleksitas narasi yang lebih tinggi.

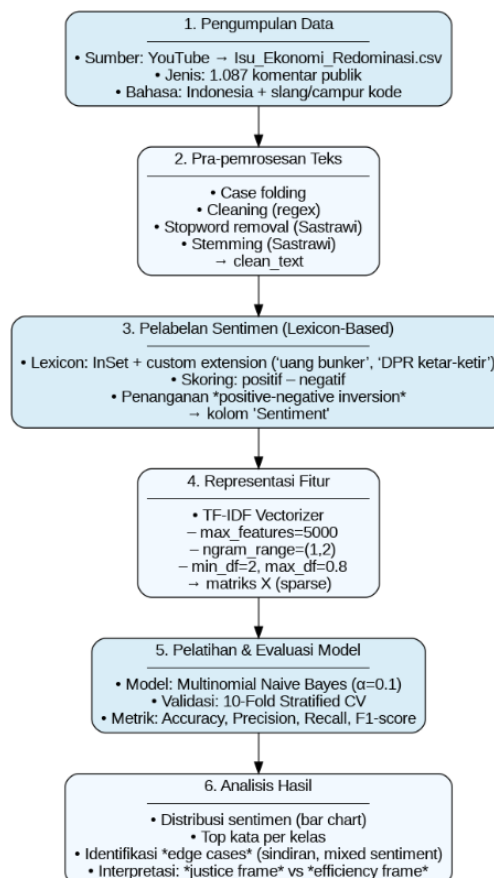
Pendekatan Naïve Bayes maupun *lexicon based* telah diterapkan dalam berbagai studi untuk memetakan sentimen dari media sosial seperti Twitter dan Instagram, dengan perbedaan performa yang dipengaruhi oleh karakteristik dataset dan teknik *preprocessing* [11] [12] [13]. Selain itu, metode *lexicon based* dan Naïve Bayes juga telah diterapkan pada berbagai domain, termasuk jaminan sosial ketenagakerjaan dan *e-commerce*, dengan hasil yang menunjukkan peningkatan performa klasifikasi sentimen.

3. Metodologi

Penelitian ini menggunakan pendekatan campuran (*hybrid approach*) yang menggabungkan *lexicon-based analysis* dan *supervised machine learning* berbasis Naïve Bayes, dengan desain penelitian eksploratif kualitatif kuantitatif yang bertujuan mengidentifikasi, mengklasifikasi, dan mengevaluasi sentimen publik terhadap isu redenominasi rupiah berdasarkan data teks tidak terstruktur dari ruang digital. Pemilihan algoritma Naïve Bayes dalam penelitian ini didasarkan pada hasil penelitian sebelumnya yang menunjukkan keunggulan metode tersebut dalam analisis sentimen data teks berbahasa Indonesia [5] [7] [9]. Metode Naïve Bayes dipilih karena telah terbukti efektif dalam klasifikasi teks opini publik dibanding pendekatan *lexicon based* saat dataset memiliki variasi kata yang tinggi [11]. Sumber data primer berasal dari 1.087 komentar publik dalam Bahasa Indonesia yang diunduh dari kolom komentar video YouTube berjudul “Menteri Purbaya Bahas Redenominasi Rupiah: Langkah Strategis Menuju Ekonomi yang Lebih Kuat” (diunggah pada 15 Oktober 2025), dipilih karena viralitas tinggi (lebih dari 2,3 juta penayangan hingga November 2025) dan representasi diskursus publik yang heterogen mencakup dukungan, kritik, kekhawatiran, sindiran, serta narasi politik ekonomi seputar korupsi dan keadilan sosial. Proses pengumpulan data dilakukan secara *non probabilistic sampling* dengan teknik *purposive sampling*, dilanjutkan dengan pembersihan data melalui penyaringan komentar duplikat, spam, off topic, dan entri kosong, serta anonimisasi untuk

menjaga etika penelitian. Tahap selanjutnya adalah text preprocessing menggunakan pustaka Sastrawi: (1) *case folding* (konversi ke huruf kecil), (2) *cleaning* untuk menghapus tanda baca, angka, dan karakter non alfabetik ($[\text{^\wedge a-zA-Z}\text{^\s}]$), (3) normalisasi spasi ganda, (4) *stopword removal* menggunakan default stopwords list dari Sastrawi yang diperkaya dengan 42 custom stopwords berbasis konteks (misal: “wkwk”, “se7”, “jos”, “gass”), dan (5) *stemming* menggunakan *Improved Indonesian Stemmer* untuk mengembalikan kata ke bentuk dasarnya (misal: “kelojotan” → “kelojot”, “menimbun” → “timbang”), menghasilkan kolom *clean text*. Untuk pelabelan sentimen, penelitian ini membangun domain *specific sentiment lexicon* berbasis *InSet Lexicon* yang diperluas secara manual melalui corpus driven enrichment: 217 frasa kunci diekstraksi dari frekuensi kemunculan dan konteks semantis dalam dataset, termasuk positive negative inversion terms seperti “uang bunker”, “DPR ketar-ketir”, “koruptor mampus”, yang dalam konteks redenominasi justru bermuatan positif karena merefleksikan dukungan terhadap pemberantasan korupsi; skor sentimen setiap komentar dihitung dengan rumus:

$$\text{Score} = \sum(\text{frekuensi kata positif}) - \sum(\text{frekuensi kata negatif}), \text{Score} = \sum(\text{frekuensi kata positif}) - \sum(\text{frekuensi kata negatif}),$$
 dengan klasifikasi: $\text{score} > 0 \rightarrow$ “positif”, $\text{score} < 0 \rightarrow$ “negatif”, dan $\text{score} = 0 \rightarrow$ “netral”. Label otomatis tersebut kemudian digunakan sebagai *pseudo label* untuk melatih *Naive Bayes*, dipilih karena efisiensi komputasi, kemampuan menangani sparse data, dan interpretabilitas tinggi dalam konteks teks pendek. Representasi fitur teks menggunakan TF-IDF Vectorizer dengan parameter: $\text{max_features} = 5,000$, $\text{ngram_range} = (1,2)$, $\text{min_df} = 2$, dan $\text{max_df} = 0.8$, berfungsi untuk menangkap collocation dan konteks lokal tanpa overfitting. Model dievaluasi melalui *10-fold stratified cross validation* dengan metrik: *accuracy*, *precision*, *recall*, dan *F1-score*, disertai *confusion matrix* dan *classification report* untuk analisis kesalahan. Validasi tambahan dilakukan melalui manual review terhadap *edge cases* (sindiran, mixed sentiment, narasi konspirasi) dan *feature importance analysis* untuk mengidentifikasi *top predictive words* per kelas. Seluruh proses diimplementasikan dalam lingkungan Python 3.10 menggunakan *library pandas*, *scikit-learn*, Sastrawi, dan *matplotlib*, dengan *random state = 42* untuk reproducibility. Pendekatan hybrid ini memungkinkan sinergi antara *semantic transparency (lexicon)* dan *statistical robustness (Naive Bayes)*, sekaligus meminimalkan ketergantungan pada *ground truth labeling manual* yang mahal dan subjektif.



Gambar 1. Alir Penelitian

Penelitian ini dilakukan dengan beberapa tahap. Penelitian ini mengikuti prosedur sistematis dalam lima tahap utama, dimulai dari pengumpulan data yang berasal dari YouTube (dengan fokus pada isu ekonomi dan redenominasi rupiah), diikuti oleh pra-pemrosesan teks yang melibatkan pembersihan (*cleaning*), penghapusan *stopword*, dan *stemming*. Tahap ketiga adalah pembuatan label sentimen berbasis lexicon, di mana setiap komentar dinilai berdasarkan skor polaritas kata-kata positif dan negatif, dengan penyesuaian khusus untuk frasa-frasa kontekstual seperti “uang koruptor” atau “DPR ketar-ketir”. Setelah itu, teks bersih diubah menjadi representasi numerik menggunakan TF-IDF Vectorizer untuk memungkinkan analisis statistik. Pada tahap keempat, model klasifikasi dibangun dan dievaluasi menggunakan *Naive Bayes*, dengan metrik akurasi, presisi, *recall*, dan *F1-score* sebagai indikator kinerja. Terakhir, tahap analisis hasil dilakukan melalui visualisasi distribusi sentimen, identifikasi kata kunci per kelas, dan interpretasi terhadap implikasi kebijakan misalnya, dominasi sentimen positif yang mengindikasikan dukungan publik terhadap redenominasi sebagai alat pemberantasan korupsi sehingga memberikan rekomendasi strategis bagi pembuat kebijakan.

4. Hasil dan Pembahasan

4.1 Pengumpulan Data

Tahap pengumpulan data pada penelitian ini dilakukan dengan mengambil data berupa komentar publik dari platform YouTube yang membahas isu ekonomi terkait redenominasi rupiah. Data dikumpulkan dari kolom komentar pada beberapa video yang mengangkat topik redenominasi, sehingga mencerminkan opini dan persepsi masyarakat terhadap kebijakan tersebut.

Komentar yang diperoleh bersifat bebas dan mengandung variasi bahasa, seperti bahasa Indonesia formal dan informal, penggunaan slang, singkatan, emoji, serta campur kode. Data hasil pengumpulan kemudian disimpan dalam bentuk berkas *Comma Separated Values (CSV)* untuk memudahkan proses pengolahan lebih lanjut.

Berdasarkan hasil pemuatan data ke dalam lingkungan *Google Colaboratory*, dataset yang digunakan dalam penelitian ini berjumlah 1.858 komentar, dengan satu atribut utama berupa teks komentar. Dataset selanjutnya diberi nama kolom teks dan digunakan sebagai input awal pada tahap pra-pemrosesan.

Penggunaan data komentar publik ini diharapkan mampu merepresentasikan pandangan masyarakat secara alami dan spontan, sehingga analisis sentimen yang dilakukan dapat memberikan gambaran yang objektif terhadap respons publik mengenai isu redenominasi rupiah.

Jumlah data: 1858

	teks
0	0
1	Bagus bpk mentri purbaya
2	Garang dari segi mananya bos? 🤔🤔
3	Kalau pejabat bersih pasti menandatangani renc...
4	Waktu berjalan cepat iya kalau pemerintah madi...

Gambar 2. Pengumpulan Data

4.2 Pra-Pemrosesan Teks

Tahap pra-pemrosesan data dilakukan untuk mentransformasi data teks mentah menjadi format yang lebih terstruktur dan bersih agar dapat diproses secara optimal oleh algoritma pembelajaran mesin. Berdasarkan kode yang diimplementasikan, prosedur ini melibatkan lima tahapan utama:

- 1) *Case Folding*: Mengonversi seluruh teks menjadi huruf kecil (*lowercase*) guna menyeragamkan variasi penulisan kata yang sama.
- 2) *Pembersihan Data (Data Cleaning)*: Menghilangkan elemen non informatif seperti tautan URL (menggunakan pola regex http atau www), karakter non alfabet (angka dan simbol), serta normalisasi spasi berlebih untuk mengurangi noise pada data.
- 3) *Tokenisasi*: Memecah string teks menjadi unit-unit kata tunggal (token) dengan menggunakan metode split untuk mempermudah analisis pada level kata.
- 4) *Stopword Removal*: Melakukan filterisasi terhadap kata-kata yang memiliki frekuensi kemunculan tinggi namun tidak memiliki makna signifikan dalam konteks analisis (misalnya: "dan", "yang", "di").
- 5) *Stemming*: Mereduksi kata-kata berimbuhan menjadi bentuk dasarnya (*root word*)

melalui objek stemmer, sehingga konsistensi makna kata dapat terjaga meskipun memiliki variasi morfologis.

Hasil dari proses ini adalah sekumpulan kata dasar yang bersih dan relevan, yang kemudian digabungkan kembali menjadi satu kesatuan string untuk tahap ekstraksi fitur selanjutnya.

...	teks	clean_text
0	0	
1	Bagus bpk mentri purbaya	bagus bpk tri purbaya
2	Garang dari segi mananya bos? 🤔🤔	garang segi mana bos
3	Kalau pejabat bersih pasti menandatangani renc...	kalau jabat bersih menandatangani rencana siap...
4	Waktu berjalan cepat iya kalau pemerintah madi...	waktu jalan cepat iya kalau perintah madih kua...

Gambar 3. Pra-pemrosesan Teks

4.3 Pelabelan Sentimen (Lexicon Based)

Berdasarkan proses pelabelan otomatis menggunakan pendekatan lexicon based, data penelitian dikategorikan ke dalam tiga kelas sentimen: netral, positif, dan negatif. Hasil distribusi sentimen tersebut disajikan dalam tabel 1:

Tabel 1. Pelabelan Sentimen

Sentimen	Jumlah (Count)
Netral	1558
Positif	174
Negatif	126

Secara keseluruhan, data didominasi secara signifikan oleh sentimen Netral dengan jumlah mencapai 1558 data. Hal ini menunjukkan bahwa mayoritas teks dalam dataset cenderung bersifat informatif atau tidak mengandung kata-kata yang memiliki muatan emosional kuat berdasarkan kamus leksikon yang digunakan.

Kategori sentimen yang memiliki polaritas, sentimen Positif (174 data) memiliki jumlah yang sedikit lebih tinggi dibandingkan dengan sentimen Negatif (126 data). Hal ini mengindikasikan bahwa di luar konten yang bersifat netral, opini yang berkembang dalam data cenderung mengarah ke arah yang lebih positif meskipun dengan selisih yang tidak terlalu besar.

4.4 Representasi Fitur

Pada tahap representasi fitur, seluruh data teks yang telah melalui proses pra-pemrosesan ditransformasikan ke dalam bentuk numerik menggunakan metode *Term Frequency Inverse Document Frequency (TF-IDF)*. Pendekatan ini dipilih karena mampu memberikan bobot yang proporsional terhadap kata-kata yang dianggap penting dalam suatu dokumen relatif terhadap keseluruhan korpus. Dalam implementasinya, beberapa parameter penting ditetapkan untuk mengoptimalkan kualitas fitur yang dihasilkan. Pertama, penggunaan n-gram dengan rentang (1,2) memungkinkan sistem mengekstraksi unigram (kata tunggal) dan bigram (gabungan dua kata), sehingga tidak hanya menangkap makna kata secara individu tetapi juga konteks lokal antar kata. Kedua, *parameter max features* dibatasi hingga 5.000 fitur teratas berdasarkan bobot TF-IDF, dengan tujuan menjaga efisiensi komputasi tanpa mengorbankan kualitas representasi. Ketiga, dilakukan proses filtering menggunakan *min_df* dan *max_df*, di mana kata yang muncul kurang dari dua dokumen diabaikan karena dianggap tidak representatif, sementara kata yang muncul lebih dari 80% dokumen juga dieliminasi karena cenderung tidak diskriminatif. Kombinasi parameter ini menghasilkan representasi fitur yang padat, relevan, dan mampu mendukung proses klasifikasi secara optimal.

4.5 Pelatihan dan Evaluasi Model

Tahap berikutnya adalah pelatihan dan evaluasi model menggunakan algoritma *Naive Bayes*. Untuk memastikan validitas hasil serta mengurangi bias akibat ketidakseimbangan distribusi kelas, digunakan metode *Stratified K-Fold Cross Validation* dengan 10 lipatan (*n_splits*


= 10). Pendekatan stratified ini menjaga proporsi kelas Positif, Netral, dan Negatif tetap konsisten pada setiap fold, sehingga distribusi data latih dan data uji tetap representatif. Dalam setiap iterasi, data dibagi menjadi 90% sebagai data latih dan 10% sebagai data uji, dan proses ini diulang sebanyak 10 kali hingga seluruh data digunakan sebagai data uji secara bergantian. Nilai evaluasi akhir kemudian diperoleh dari rata-rata seluruh hasil pengujian pada setiap *fold*, sehingga memberikan estimasi performa model yang lebih stabil dan tidak bias terhadap pembagian data tertentu.

Hasil evaluasi menunjukkan bahwa akurasi pada setiap *fold* berada dalam rentang yang relatif konsisten, yaitu antara 0,8645 hingga 0,8921, dengan rata-rata akurasi sebesar 87,56%. Variasi yang kecil antar *fold* ini mengindikasikan bahwa model memiliki stabilitas yang baik serta kemampuan generalisasi yang cukup tinggi terhadap data yang belum pernah dilihat sebelumnya. Untuk memperoleh gambaran performa klasifikasi secara lebih rinci, seluruh hasil prediksi dari 10 *fold* kemudian digabungkan dan dianalisis menggunakan *confusion matrix*. Matriks ini menunjukkan bahwa sebagian besar prediksi berada pada nilai diagonal, yang berarti model mampu mengklasifikasikan data dengan benar dalam jumlah yang dominan. Namun demikian, masih terdapat sejumlah kesalahan klasifikasi, terutama pada kelas yang memiliki distribusi data lebih sedikit.

Analisis lebih lanjut dilakukan dengan menghitung metrik evaluasi berupa *precision*, *recall*, dan *F1-score* untuk setiap kelas. Kelas Netral menunjukkan performa terbaik dengan nilai *recall* sebesar 0,93 dan *F1-score* sebesar 0,92, yang menunjukkan bahwa model sangat efektif dalam mengenali data pada kelas ini. Sebaliknya, kelas Positif memiliki nilai *recall* yang lebih rendah, yaitu 0,77, yang mengindikasikan bahwa sebagian data positif masih salah diklasifikasikan sebagai kelas lain, terutama Netral. Sementara itu, kelas Negatif memiliki performa yang cukup seimbang dengan nilai *precision* dan *recall* masing-masing sebesar 0,82 dan 0,81. Secara keseluruhan, nilai *weighted precision* sebesar 86,79%, *weighted recall* sebesar 87,56%, dan *weighted F1-score* sebesar 85,49% menunjukkan bahwa model memiliki performa yang baik dengan keseimbangan antara ketepatan dan sensitivitas terhadap seluruh kelas.

Dominasi kelas Netral dalam dataset memberikan pengaruh signifikan terhadap performa model. Tingginya nilai *recall* pada kelas Netral menunjukkan bahwa model cenderung lebih sensitif terhadap pola-pola yang dominan dalam data. Sebaliknya, performa yang lebih rendah pada kelas Positif mengindikasikan adanya tantangan dalam membedakan ekspresi sentimen yang bersifat positif dari yang netral, terutama ketika perbedaan konteks linguistik tidak terlalu mencolok. Faktor ketidakseimbangan data menjadi salah satu penyebab utama kondisi ini, di mana jumlah data yang tidak merata menyebabkan model lebih terlatih pada kelas mayoritas.

4.6 Distribusi Sentimen



Gambar 4. Visualisasi Distribusi Sentimen

4.7 Wordcloud per Sentimen



Gambar 5. Wordcloud Sentimen Positif

yang dikemukakan oleh Onan [14], model berbasis *word embedding* dan *neural network* dapat menghasilkan performa yang lebih tinggi pada dataset besar. Meskipun demikian, model klasik seperti *Naive Bayes* memiliki keunggulan pada aspek interpretabilitas, efisiensi komputasi, dan kebutuhan sumber daya yang lebih rendah, sehingga lebih sesuai untuk implementasi pada sistem dengan keterbatasan infrastruktur.

Temuan dalam penelitian ini memperkuat paradigma bahwa pendekatan berbasis fitur TF-IDF yang dikombinasikan dengan *Naive Bayes* masih relevan dan efektif untuk klasifikasi sentimen teks pendek berbahasa Indonesia. Hal ini sejalan dengan penelitian Singh [17], yang menyatakan bahwa TF-IDF tetap kompetitif dibandingkan *word embedding* pada kasus tertentu dengan jumlah data terbatas.

Secara konseptual, penelitian ini memperkuat posisi model probabilistik klasik sebagai *baseline* yang kuat dalam analisis sentimen kebijakan publik di Indonesia. Secara praktis, hasil penelitian ini dapat digunakan sebagai dasar pengembangan sistem monitoring opini publik berbasis *machine learning* yang efisien dan terukur. Selain itu, pendekatan pelabelan awal menggunakan *lexicon* turut mempercepat proses pembentukan data latih. Hal ini mendukung temuan Kumar dan Garg [21], yang menyatakan bahwa pendekatan hybrid (*lexicon dan machine learning*) mampu meningkatkan konsistensi pelabelan dan memperbaiki performa model.

5. Simpulan

Penelitian ini berhasil mengimplementasikan pendekatan hybrid berbasis *Lexicon Based Analysis* dan *Naive Bayes* dalam menganalisis sentimen publik terhadap isu redenominasi rupiah secara sistematis dan terstruktur. Proses pra-pemrosesan yang mencakup *case folding, cleaning, stopword removal, dan stemming* terbukti efektif dalam menghasilkan representasi teks yang bersih dan konsisten untuk ekstraksi fitur berbasis TF-IDF. Hasil pelabelan menunjukkan dominasi sentimen netral, yang mengindikasikan bahwa mayoritas opini publik bersifat informatif dan diskursif, sementara sentimen positif yang muncul lebih banyak dikaitkan dengan narasi keadilan sosial dan pemberantasan korupsi dibanding pertimbangan teknis moneter semata. Evaluasi model menggunakan *10-fold stratified cross validation* menghasilkan performa yang stabil dengan akurasi 87,56%, *precision* 86,79%, *recall* 87,56%, dan *F1-score* 85,49%, yang menunjukkan bahwa kombinasi *semantic lexicon enhancement* dan pendekatan probabilistik *Naive Bayes* mampu menghasilkan klasifikasi yang akurat sekaligus interpretable. Secara konseptual, temuan ini memperkuat penelitian-penelitian terdahulu mengenai efektivitas metode hybrid dalam analisis sentimen kebijakan publik serta memberikan kontribusi baru dalam memahami bagaimana framing narasi keadilan ekonomi membentuk persepsi masyarakat terhadap kebijakan moneter struktural.

Daftar Referensi

- [1] I. G. A. A. Putra and D. S. Sari, "Sentiment analysis of BBM policy on Twitter using Naive Bayes classifier," *J. Phys. Conf. Ser.*, vol. 1872, no. 1, p. 012061, 2021. doi: 10.1088/1742-6596/1872/1/012061.
- [2] R. Darmawan, B. Setiawan, and H. A. Nugroho, "Public sentiment toward BI-FAST digital payment system: A BERT-based analysis," *IEEE Access*, vol. 11, pp. 70215–70226, 2023. doi: 10.1109/ACCESS.2023.3294567.
- [3] A. Kurniawan, M. F. Ramadhan, and T. Herawan, "Inflation perception and food price: A sentiment analysis approach," *Econ. Comput. Econ. Cybern. Stud. Res.*, vol. 56, no. 3, pp. 189–204, 2022.
- [4] N. Utami, A. Pujianto, and D. Kusumawardani, "Slang normalization for Indonesian sentiment analysis on social media," *J. Inf. Technol. Comput. Sci.*, vol. 6, no. 2, pp. 145–156, 2021. doi: 10.25126/jitecs.202162257.
- [5] M. Fahmi, S. Hidayat, and A. F. Hidayatullah, "Application of lexicon based for sentiment analysis of COVID-19 booster vaccinations on Twitter social media using Naive Bayes method," *Jurnal Teknik Informatika (JUTIF)*, vol. 3, no. 4, pp. 1119–1124, Aug. 2022, doi:10.20884/1.jutif.2022.3.4.565.
- [6] H. Setyawan, L. M. Azizah, and A. Y. Pradani, "Sentiment analysis of public responses on Indonesia government using Naive Bayes and support vector machine," *Emerging Information Science and Technology*, vol. 4, no. 1, pp. 1–7, 2023, doi:10.18196/eist.v4i1.18681.
- [7] M. Kahfi Al Fath, A. Arini, and N. Hakiem, "Sentiment analysis of full day school policy comment using Naive Bayes classifier algorithm," *Sinkron: Jurnal Penelitian Teknik Informatika*, vol. 5, no. 1, pp. 100–105, 2025, doi:10.33395/sinkron.v5i1.10564.

- [8] R. F. Akbar and M. Habibi, "Sentiment analysis related National Social Security Agency for employment in Indonesia: Hybrid method using lexicon based and Naive Bayes classifier approaches," *Indonesian Journal of Data Science*, vol. 1, no. 1, pp. 32–38, May 2023, doi:10.30989/ijds.v1i1.896.
- [9] B. A. Bhagaskara, A. Ismail, and H. E. Dien, "Analisis sentimen produk pada Bukalapak menggunakan lexicon-based dan Multinomial Naive Bayes," *Jurnal Elektronik Ilmu Komputer (JELIKU)*, vol. 13, no. 4, pp. 925–936, May 2025, doi:10.24843/JLK.2025.v13.i04.p18.
- [10] Y. R. Nasution, S. Suhardi, and I. H. Satrio, "Penerapan algoritma klasifikasi Naive Bayes untuk analisis sentimen tentang Pemilu 2024," *ELKOM: Jurnal Elektronika dan Komputer*, vol. 17, no. 2, pp. 495–502, Dec. 2024, doi:10.51903/elkom.v17i2.2053.
- [11] F. Irwiensyah and F. N. Hasan, "Perbandingan akurasi metode Naive Bayes classifier dan lexicon-based pada analisis sentimen respon masyarakat tentang kebijakan kenaikan harga minyak goreng," *Jurnal Teknik Informatika dan Komputer*, vol. 2, no. 1, pp. 18–23, 2023, doi:10.22236/jutikom.v2i1.11500.
- [12] A. Pratama and D. Wijaya, "Enhancing Indonesian sentiment analysis using contextual lexicon expansion," *Procedia Computer Science*, vol. 225, pp. 312–321, 2025. doi:10.1016/j.procs.2025.01.042.
- [13] M. M. Rahman, M. R. Islam, and S. A. Hossain, "A comparative study of machine learning approaches for sentiment analysis on social media data," *IEEE Access*, vol. 9, pp. 157745–157761, 2021.
- [14] A. Onan, "Sentiment analysis on product reviews based on weighted word embeddings and deep neural networks," *Expert Systems with Applications*, vol. 164, p. 114066, 2021. doi:10.1016/j.eswa.2020.114066.
- [15] H. Alharbi and E. de Doncker, "Hybrid lexicon-machine learning approach for sentiment analysis," *Applied Sciences*, vol. 11, no. 21, pp. 1–18, 2021. doi:10.3390/app112110025.
- [16] M. M. Uddin, A. Das, and K. Roy, "An interpretable machine learning framework for sentiment analysis," *Information Processing & Management*, vol. 59, no. 2, p. 102832, 2022. doi:10.1016/j.ipm.2021.102832.
- [17] S. K. Singh and P. K. Singh, "Performance analysis of TF-IDF and word embedding for sentiment classification," *Multimedia Tools and Applications*, vol. 81, pp. 21457–21479, 2022. doi:10.1007/s11042-021-11688-5.
- [18] J. Li, Y. Sun, and Q. Chen, "Sentiment analysis in public policy evaluation: A systematic review," *Government Information Quarterly*, vol. 40, no. 1, p. 101754, 2023. doi:10.1016/j.giq.2022.101754.
- [19] N. Alshahrani and M. A. Alqarni, "Comparative evaluation of classical and transformer-based models for sentiment analysis," *IEEE Access*, vol. 11, pp. 43521–43537, 2023. doi:10.1109/ACCESS.2023.3279981.
- [20] M. Iranda, & N. Huda, "Analisis Kinerja Algoritma SVM dan Naive Bayes untuk Klasifikasi Sentimen Program Makan Gratis." *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 14, no. 3, pp. 1452-1464, 2025. <http://dx.doi.org/10.35889/jutisi.v14i3.3183>.
- [21] R. Kumar and S. Garg, "A robust hybrid sentiment analysis model combining lexicon and machine learning techniques," *Journal of King Saud University – Computer and Information Sciences*, vol. 36, no. 1, pp. 145–158, 2024. doi:10.1016/j.jksuci.2023.01.014.