



Analisis sentimen omnibus law di Twitter dengan machine learning dan teknik resampling

Arif Dwi Syafutra, Kusri

Universitas AMIKOM Yogyakarta, Indonesia

Riwayat Artikel:

Diterima 14 Maret 2025

Direvisi 20 April 2025

Disetujui 22 April 2025

Kata Kunci:

Analisis sentimen

Machine learning

Omnibus law

Teknik resampling

Twitter

ABSTRACT. The Omnibus Law has been a controversial issue in Indonesia since its enactment in 2020, sparking widespread public debate on social media platforms, particularly Twitter. This study aims to classify public sentiment toward the Omnibus Law using machine learning algorithms and resampling techniques to address data imbalance. A total of 20,000 tweets were collected via web scraping, processed using Natural Language Processing (NLP) methods, and automatically labeled through a lexicon-based approach. The final dataset consisted of 17,184 tweets categorized into positive and negative sentiments. Sentiment classification models were developed using Support Vector Machine (SVM), Random Forest, and Multinomial Naïve Bayes, with Synthetic Minority Oversampling Technique (SMOTE) and Random Undersampling applied to enhance model performance. Evaluation results show that SVM combined with SMOTE achieved the highest performance with an accuracy of 93.08%, a recall of 92.85%, and a precision of 92.44%, outperforming other algorithms. These findings highlight that resampling techniques, particularly SMOTE, significantly improve classification performance in handling imbalanced datasets. This study emphasizes the importance of selecting appropriate algorithms and balancing strategies to enhance sentiment analysis accuracy based on social media data. Furthermore, the results open opportunities for future research to explore deep learning-based approaches for more complex public opinion analysis.

ABSTRAK. Omnibus Law telah menjadi isu kontroversial di Indonesia sejak pengesahannya pada tahun 2020 yang mendorong perdebatan luas di media sosial, khususnya Twitter. Penelitian ini bertujuan untuk mengklasifikasikan sentimen publik terhadap Omnibus Law menggunakan algoritma machine learning dan teknik resampling untuk mengatasi ketidakseimbangan data. Data sebanyak 20.000 tweet dikumpulkan melalui web scraping, diproses dengan metode Natural Language Processing (NLP), dan dilabeli secara otomatis menggunakan pendekatan berbasis lexicon. Dataset akhir terdiri atas 17.184 tweet dengan kategori sentimen positif dan negatif. Model klasifikasi dikembangkan menggunakan Support Vector Machine (SVM), Random Forest, dan Multinomial Naïve Bayes, dengan penerapan teknik Synthetic Minority Oversampling Technique (SMOTE) dan Random Undersampling untuk meningkatkan performa. Hasil evaluasi menunjukkan bahwa SVM dengan SMOTE menghasilkan akurasi tertinggi sebesar 93,08%, recall 92,85%, dan precision 92,44%, mengungguli algoritma lainnya. Temuan ini menunjukkan bahwa teknik resampling, khususnya SMOTE, secara signifikan memperbaiki performa klasifikasi dalam skenario data tidak seimbang. Penelitian ini menegaskan pentingnya kombinasi antara pemilihan algoritma yang tepat dan strategi balancing data untuk meningkatkan akurasi analisis sentimen berbasis media sosial. Studi ini juga membuka peluang penelitian lanjutan menggunakan pendekatan deep learning untuk klasifikasi opini publik yang lebih kompleks.

This is an open-access article under the [CC-BY-SA](#) license.



Penulis Korespondensi:

Arif Dwi Syafutra,

Universitas AMIKOM Yogyakarta,

Jl. Ring Road Utara, Yogyakarta 55281, Indonesia.

Email: arifdwi@students.amikom.ac.id

PENDAHULUAN

Omnibus Law atau Undang-Undang Cipta Kerja telah menjadi topik hangat dalam diskusi publik di Indonesia sejak disahkan pada tahun 2020. Undang-undang ini bertujuan untuk menyederhanakan perizinan, meningkatkan investasi, serta merampingkan ketentuan ketenagakerjaan (Pane dkk., 2021). Namun, respons masyarakat sangat beragam. Sebagian pihak menilai UU ini mampu mempercepat pertumbuhan ekonomi dengan menciptakan lebih banyak lapangan kerja dan menarik investasi asing. Di sisi lain, banyak yang menolak karena menganggap kebijakan ini menguntungkan pengusaha dan merugikan pekerja, terutama karena adanya pemangkasan hak-hak ketenagakerjaan yang sebelumnya dilindungi (Adnyana dkk., 2021).

Perdebatan mengenai Omnibus Law meluas ke media sosial, khususnya Twitter, yang menjadi saluran utama masyarakat Indonesia dalam menyampaikan opini terhadap isu-isu publik. Twitter memungkinkan penyebaran informasi dan pandangan secara masif dalam waktu singkat, yang pada akhirnya membentuk persepsi publik terhadap kebijakan tertentu (Wang dkk., 2022). Dalam konteks ini, analisis sentimen menjadi alat yang relevan untuk mengeksplorasi opini masyarakat dan mengidentifikasi polarisasi sikap publik.

Analisis sentimen merupakan metode populer untuk mengelompokkan opini menjadi kategori positif, negatif, atau netral. Pendekatan ini sangat berguna bagi pembuat kebijakan dan pemangku kepentingan dalam mengevaluasi respons masyarakat serta memahami isu-isu yang dianggap penting oleh publik (Sucahyo dkk., 2020). Namun, klasifikasi sentimen di media sosial menghadapi sejumlah tantangan, seperti penggunaan bahasa informal, sarkasme, dan ironi, yang dapat menurunkan akurasi klasifikasi (Lee, 2024). Oleh karena itu, pendekatan berbasis pemrosesan bahasa alami (NLP) dan algoritma pembelajaran mesin diperlukan untuk memperoleh hasil analisis yang lebih andal.

Sejumlah penelitian sebelumnya telah mengkaji analisis sentimen terhadap kebijakan publik menggunakan algoritma klasifikasi. Namun, sedikit penelitian yang secara eksplisit membandingkan efektivitas model klasifikasi dengan penerapan teknik resampling seperti SMOTE dalam konteks sentimen terhadap Omnibus Law. Selain itu, belum banyak studi yang mengkaji dampak pemilihan rasio data latih-uji terhadap performa model dalam skenario data tidak seimbang.

METODE

Data

Data dikumpulkan dari platform Twitter menggunakan teknik web scraping berbasis kata kunci seperti #CiptaKerja, #OmnibusLaw, dan #TolakOmnibusLaw. Periode pengumpulan berlangsung dari Juli 2020 hingga April 2023, menghasilkan 20.000 tweet berbahasa Indonesia. Setelah melalui proses filtering, khususnya dengan menghapus tweet berlabel netral, jumlah data yang digunakan untuk pelatihan dan pengujian model adalah 17.184 tweet, terdiri dari 10.316 tweet sentimen negatif dan 6.868 tweet sentimen positif. Untuk menjaga aspek etika, hanya data yang bersifat publik dan tersedia secara terbuka melalui Twitter yang digunakan. Data pribadi seperti nama pengguna, lokasi, atau informasi sensitif lainnya tidak disimpan atau dianalisis.

Tabel 1. Daftar Sumber Data

No	Tweet	Tanggal
1	"Sudah baca kicauan dan tulisan para tokoh? Sudah nonton debat para pakar di televisi? Kalau belum, saya sarankan Anda balik keliling kota, abaikan dan biarkan protes ini berlanjut tanpa akhir. #Omnibuslaw"	2020-10-10 05:06:27
2	"Sepakat mas!!!"	2020-10-10 04:55:53

No	Tweet	Tanggal
	Masyarakat yang menetap di #Jogja dibedakan oleh penguasa menjadi: Pendetang dan Asli. Padahal kita sama sama rakyat miskin, di bawah kekuasaan yg menikmati #Danais dari seluruh Indonesia. #malioboro #GagalkanOmnibusLaw"	
3	"#OmnibusLaw jegal sampai gagal #JihadPMIIMenyala"	2020-10-10 04:52:53
4	"Saudara dipilih bukan di lotre Kami buruh butuh hidup layak #TolakOmnibusLaw"	2020-10-14 07:43:53
5	"Hai aparat senjata kalian tidak ada apa2 ny d banding kan dng senjata kami Kau cam kan itu Senjata kami umat islam hny doa aja yg akan menggetar kan arsy memohon kepada ALLAH #TolakOmnibusLaw #HentikanPenindasanRakyat #RakyatMenolakUuOmniBusLaw #UmmatBersatuTolakOmnibuslaw"	2020-10-13 08:06:27
6	Harus nya di retweet keras.. Tweet maha penting ini #TolakOmnibusLaw"	2020-10-13 04:53:27
7	"Hati-hati.. Hati-hati.. PROVOKASI...!!! #TolakOmnibusLaw #TolakUUCiptaKerja"	2020-10-13 04:40:13

Tahapan Analisis Data

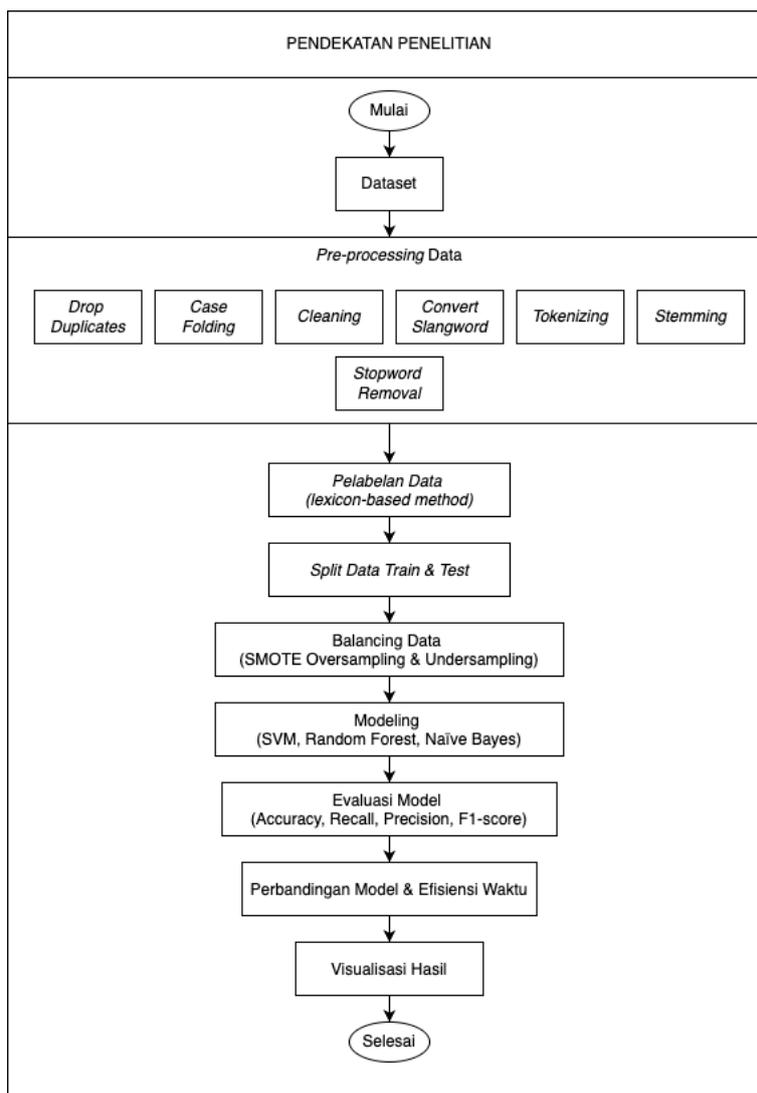
Dalam pembuatan model klasifikasi, metode yang digunakan adalah Support Vector Machine (SVM), Random Forest, dan Multinomial Naive Bayes, dengan teknik balancing data menggunakan SMOTE (Oversampling) dan Random Undersampling. Proses pengolahan data mencakup pre-processing (menghapus data duplikat, case folding, cleaning, konversi slangword, tokenizing, stemming, stopword removal, dan menghapus data kosong)(Müller & Guido, 2016). Pelabelan data dilakukan menggunakan Lexicon Based, diikuti dengan eksplorasi distribusi label sentimen. Setelah itu, data dibagi menjadi train dan test menggunakan stratified split. Untuk menangani ketidakseimbangan data, SMOTE digunakan untuk oversampling, dan Random Undersampling digunakan untuk menyeimbangkan data. Model dikembangkan dengan metode yang sesuai untuk masing-masing algoritma dan dievaluasi menggunakan accuracy, recall, precision dan f1-score (Azhari dkk., 2021). Model terbaik dipilih berdasarkan test_size optimal dan hasil evaluasi tertinggi. Langkah-langkah penelitian ini ditunjukkan dalam Gambar 1.

Pre-Processing Data

Proses pre-processing merupakan tahapan memperbaiki data teks yang tidak terstruktur menjadi data yang dapat dianalisis. Tahapan pre-processing pada data adalah sebagai berikut.

1. Drop Duplicates untuk menghilangkan duplikat komentar yang sama dari user yang sama.
2. Case Folding untuk mengubah semua teks yang mengandung huruf kapital menjadi huruf kecil.
3. Cleaning-Remove Unnecessary Character untuk menghilangkan username yang dimulai dengan mention, karakter simbol dan URL.
4. Cleaning-Remove Emoji untuk menghilangkan emoji.
5. Cleaning-Remove Non-Alpha Numeric untuk menghapus tanda baca.

6. Convert Slangwords untuk mengubah kata slang menjadi kata baku menurut Kamus Besar Bahasa Indonesia.
7. Tokenizing untuk memecah teks menjadi kata per kata.
8. Stemming untuk menghilangkan kata imbuhan sehingga diperoleh kata dasar.
9. Stopwords Removal untuk menghilangkan kata-kata yang tidak penting dalam teks dengan menghapus kata pada komentar yang terdapat dalam daftar stopwords.



Gambar 1. Diagram alur tahapan analisis data

Polarity Score dan Pelabelan Data

Pelabelan data dilakukan secara otomatis menggunakan lexicon-based sentiment analysis berbasis kamus sentimen Bahasa Indonesia. Setiap tweet dianalisis berdasarkan jumlah kata bernuansa positif dan negatif yang muncul dalam teks, kemudian dihitung skor polaritas dengan rumus (Wahyuni & Utomo, 2022) :

$$Polarity\ Score = Jumlah\ Kata\ Positif - Jumlah\ Kata\ Negatif$$

Klasifikasi sentimen dilakukan berdasarkan nilai polarity score sebagai berikut:

- Positif : score > 0
- Netral : score = 0
- Negatif : score < 0

Kamus Lexicon yang digunakan telah diadaptasi dari sumber terbuka dan penelitian sebelumnya yang relevan (Sucahyo dkk., t.t.). Meskipun metode ini belum tervalidasi secara resmi dalam skala nasional, lexicon telah diuji secara manual pada subset data untuk menjamin koherensi semantik.

Eksplorasi Data Hasil Pelabelan

Eksplorasi data hasil pelabelan dilakukan dengan visualisasi untuk menganalisis pola dan tren distribusi komentar berdasarkan polarity.

Pembagian Data (Train-Test Split)

Pada tahap ini dilakukan pembagian dataset menjadi data pelatihan (data train) dan pengujian (data test) untuk tiga perbandingan, yaitu 60%:40%, 70%:30%, 80%:20%, dan 90%: 10%.

Feature Selection

Untuk meningkatkan kinerja klasifikasi dan mengurangi dimensi fitur dalam data teks, digunakan pendekatan feature selection berbasis korelasi. Kata-kata dengan korelasi tinggi terhadap label sentimen dipertahankan, sedangkan fitur dengan kontribusi rendah dihilangkan. Pendekatan ini membantu meningkatkan efisiensi komputasi dan mengurangi noise yang dapat memengaruhi performa model.

Pembuatan Model Klasifikasi

Dalam penelitian ini, klasifikasi sentimen dilakukan menggunakan beberapa algoritma pembelajaran mesin untuk membandingkan performa masing-masing metode. Algoritma yang digunakan meliputi:

- a. *Support Vector Machine*
Algoritma yang bekerja dengan mencari hyperplane terbaik untuk memisahkan data berdasarkan margin maksimal.
- b. *Random Forest*
Metode berbasis ensemble yang menggunakan banyak pohon keputusan untuk meningkatkan akurasi dan mengurangi overfitting.
- c. *Multinomial Naïve Bayes*
Model probabilistik yang sering digunakan untuk klasifikasi teks, khususnya dalam pemrosesan bahasa alami (Sabrani dkk., 2020).
- d. *SMOTE (Synthetic Minority Oversampling Technique)*
Teknik yang digunakan untuk menangani ketidakseimbangan data dengan membuat sampel sintetis sebelum diterapkan pada model Naïve Bayes (Makhtum & Muhajir, 2023), (Wang dkk., 2022).
- e. *Random Undersampling*
Pendekatan untuk menangani ketidakseimbangan kelas dengan mengurangi jumlah sampel dari kelas mayoritas (Wankhade dkk., 2022).

Evaluasi Model

Model yang telah dibangun dievaluasi menggunakan beberapa metrik utama untuk mengukur kinerjanya, yaitu:

- a. *Akurasi*
Mengukur proporsi prediksi yang benar dari keseluruhan data uji.

- b. *Presisi*
Menunjukkan seberapa banyak prediksi positif yang benar dari seluruh prediksi positif yang dibuat.
- c. *Recall*
Mengukur seberapa baik model dalam menemukan seluruh sampel dari kelas positif.
- d. *F1-score*
Rata-rata harmonik antara presisi dan recall, yang memberikan gambaran lebih seimbang tentang performa model.

Selain itu, Confusion Matrix digunakan untuk menganalisis kesalahan klasifikasi dengan lebih rinci, membantu dalam memahami distribusi prediksi antara kelas positif dan negatif. Analisis ini penting untuk menentukan strategi perbaikan model dan meningkatkan akurasi dalam klasifikasi sentiment.

HASIL DAN DISKUSI

Pre-Processing Data

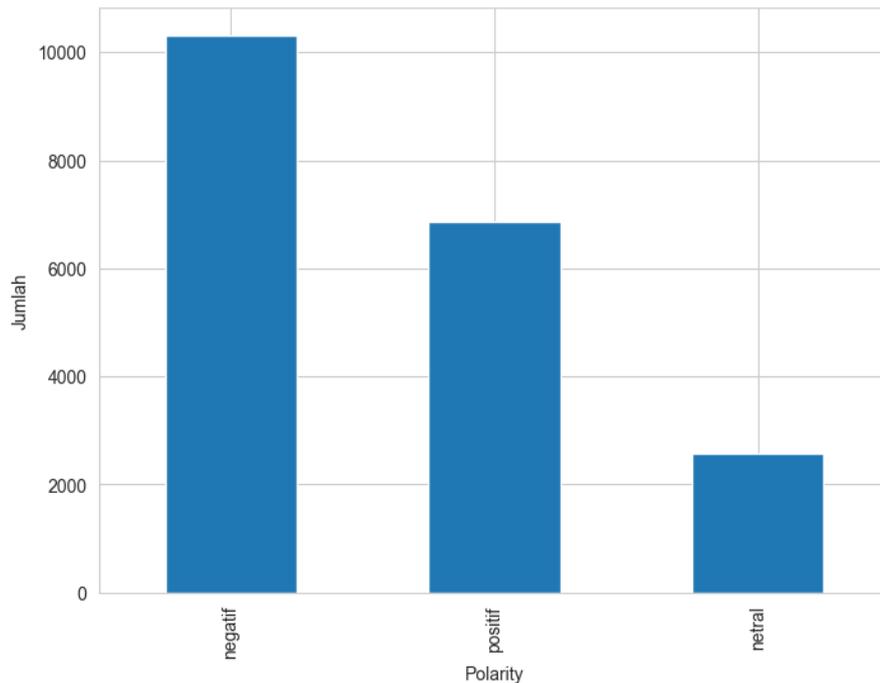
Data Tweet tentang Omnibus Law memiliki jumlah sebesar 20000 tweet memasuki tahap pre-processing terlebih dahulu untuk menyeragamkan isi dari data yang diperoleh. Adapun hasil dari setiap tahap pre-processing data dapat dilihat pada Tabel 2.

Tabel 2. Pre-processing data

Tahap	Tweet
Tweets	Teman ² oposisi tlong share kisi ² +pasal ² nya, yg merugikan dari UU #OmnibusLaw agar seluruh manusia di Indonesia tau dampak buruknya dari undang ² yg ngak jelas ini ..
Clean_review	teman oposisi tlong share kisi pasal nya yg merugikan dari uu agar seluruh manusia di indonesia tau dampak buruknya dari undang yg ngak jelas ini
Normalization	teman oposisi tlong share kisi pasal nya yang merugikan dari uu agar seluruh manusia di indonesia tahu dampak buruknya dari undang yang tidak jelas ini
Final_text	teman oposisi tlong share kisi pasal yang merugikan dari agar seluruh manusia indonesia tahu dampak buruknya dari undang yang tidak jelas
Token	['teman', 'oposisi', 'tlong', 'share', 'kisi', 'pasal', 'yang', 'merugikan', 'dari', 'agar', 'seluruh', 'manusia', 'indonesia', 'tahu', 'dampak', 'buruknya', 'dari', 'undang', 'yang', 'tidak', 'jelas']
Stop_review	['teman', 'oposisi', 'tlong', 'share', 'kisi', 'pasal', 'merugikan', 'manusia', 'indonesia', 'dampak', 'buruknya', 'undang']
Stem_review	teman oposisi tlong share kisi pasal rugi manusia indonesia dampak buruk undang
Prepos_text	['teman', 'oposisi', 'tlong', 'share', 'kisi', 'pasal', 'rugi', 'manusia', 'indonesia', 'dampak', 'buruk', 'undang']

Pelabelan Data

Setelah melalui tahap preprocessing, dilakukan pelabelan data berdasarkan nilai polarity score. Kategori Positif diberikan pada tweet dengan skor > 0, Netral = 0, dan Negatif < 0. Berdasarkan Gambar 2, mayoritas tweet tergolong sentimen negatif (10.316 tweet), diikuti sentimen positif (6.868 tweet), dan netral (2.579 tweet). Tweet netral kemudian disaring agar analisis lebih terfokus pada polaritas dominan (positif dan negatif), yang lebih relevan dalam mengukur kecenderungan opini publik secara tegas. Sebagai bentuk validasi terhadap keakuratan pelabelan otomatis berbasis lexicon, dilakukan perbandingan antara label hasil lexicon-based dengan prediksi model pembelajaran mesin, yaitu Support Vector Machine (SVM). Hasil evaluasi menunjukkan tingkat kesesuaian sebesar 93,54%, yang mengindikasikan bahwa pendekatan lexicon-based cukup andal dan konsisten dalam merepresentasikan sentimen pada data tweet.

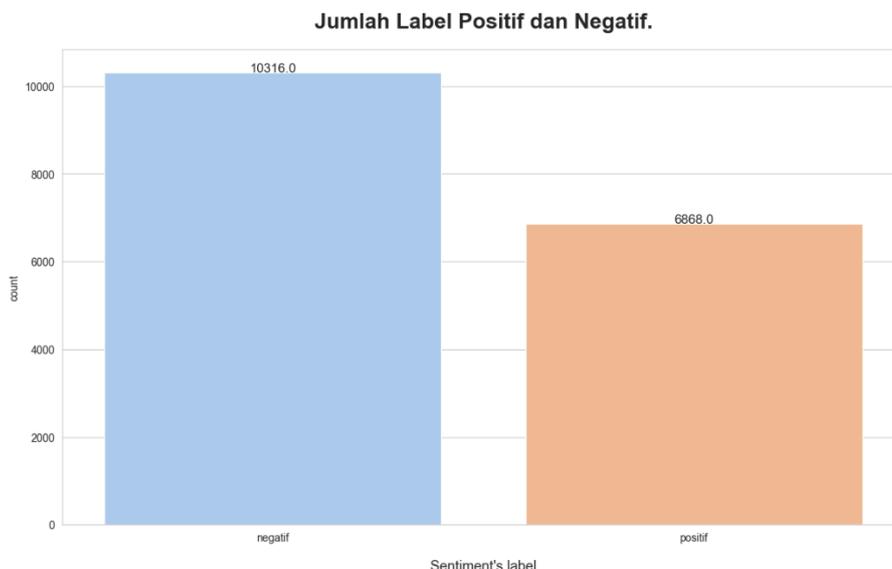


Gambar 2. Distribusi kelas sentimen sebelum *filtering*

Tingkat akurasi yang tinggi ini menunjukkan bahwa kamus lexicon yang digunakan mampu menangkap nuansa semantik dari kata-kata opini publik secara efektif. Validasi ini memperkuat argumentasi bahwa pelabelan otomatis berbasis lexicon dapat menjadi alternatif yang layak dan efisien, terutama ketika pelabelan manual dalam jumlah besar tidak memungkinkan secara praktis. Pendekatan serupa juga digunakan pada penelitian terdahulu dalam klasifikasi sentimen kebijakan new normal, yang memanfaatkan analisis berbasis polaritas dan menunjukkan hasil dominan pada kategori sentimen positif dan netral, memperkuat peran analisis leksikal dalam studi opini publik (Dwitiyanti & Selvia, 2021). Oleh karena itu, hasil pelabelan tersebut layak digunakan sebagai ground truth dalam proses pelatihan dan evaluasi model klasifikasi sentimen lebih lanjut.

Berdasarkan hasil pre-processing dan pelabelan sentimen, distribusi awal menunjukkan bahwa kelas sentimen negatif memiliki frekuensi paling tinggi, yaitu 10.316 tweet (sekitar 60% dari total), diikuti oleh 6.868 tweet positif (sekitar 40%), dan 2.579 tweet netral (sekitar 13%). Proporsi tweet netral yang relatif kecil ini dipandang kurang memberikan kontribusi signifikan dalam klasifikasi biner yang fokus pada dua kutub emosi: afirmatif (positif) dan resistif (negatif). Untuk itu, dilakukan penyaringan manual terhadap tweet netral demi menyederhanakan struktur target kelas, serta menghindari ambiguitas semantik yang dapat memperlemah efektivitas model dalam menangkap polarisasi opini publik.

Hasilnya, dataset akhir hanya terdiri dari dua kategori utama, yakni 10.316 tweet negatif dan 6.868 tweet positif, dengan total 17.184 tweet yang digunakan dalam pelatihan dan pengujian model. Jumlah ini mencakup sekitar 85,9% dari total data awal yang berhasil dikurasi secara etis, dengan hanya mencantumkan data publik tanpa memuat informasi pribadi seperti nama pengguna atau lokasi. Pendekatan ini memungkinkan model pembelajaran mesin untuk fokus secara optimal pada perbedaan sentimen utama, serta meminimalkan risiko bias yang muncul dari distribusi label tidak seimbang. Visualisasi pada Gambar 3 menggambarkan representasi grafis dari distribusi kelas sentimen setelah filtering, yang menunjukkan adanya dominasi opini negatif terhadap Omnibus Law dalam wacana publik di Twitter. Konfigurasi ini juga mendukung proses evaluasi model yang lebih terarah, terutama dalam konteks pengambilan keputusan berbasis opini masyarakat digital terhadap kebijakan yang kontroversial.



Gambar 3. Distribusi kelas sentimen sesudah filtering

Exploratory Data Hasil Pelabelan



Gambar 4. Wordcloud kelas sentiment Positif dan Negatif

Berdasarkan Gambar 4, hasil visualisasi kata (word cloud) menggambarkan distribusi kosakata dominan dari tweet berlabel sentimen negatif dan positif terkait Omnibus Law Cipta Kerja. Pada kelas sentimen negatif, kata-kata yang paling menonjol mencakup: “kerja”, “tolak omnibus”, “tolak”, “cipta”, “demo”, “rakyat”, “buruh”, “rezim”, dan “omnibus”. Kata-kata ini secara jelas mencerminkan ekspresi penolakan, keresahan sosial, dan resistensi publik terhadap kebijakan tersebut. Istilah seperti “demo” dan “rakyat” mengindikasikan adanya mobilisasi sosial yang cukup kuat dan keterlibatan publik secara luas dalam menyuarakan kritik di media sosial, terutama berkaitan dengan isu perburuhan dan ketimpangan kebijakan.

Sebaliknya, pada kelas sentimen positif, word cloud memperlihatkan dominasi kata-kata seperti “kerja”, “cipta”, “lapangan”, “investasi”, “pemerintah”, dan “pertumbuhan”. Hal ini menunjukkan adanya narasi optimis yang dibangun oleh sebagian masyarakat yang mendukung UU Cipta Kerja karena diyakini mampu membuka lapangan pekerjaan baru, meningkatkan efisiensi perizinan, serta menarik investasi asing ke Indonesia. Kata “aksi” dan “perubahan” juga muncul dalam konteks positif, menunjukkan adanya harapan terhadap transformasi ekonomi nasional melalui regulasi yang lebih terintegrasi.

Perbedaan fokus kosakata antara dua kutub sentimen ini menegaskan adanya polarisasi opini publik yang tajam terhadap Omnibus Law di platform Twitter. Visualisasi ini menjadi alat penting dalam memahami konstruksi opini massa dan persebaran narasi digital yang berkembang di ruang publik daring.

Label Encoding

Digunakan pembuat encode Label Encoder untuk mengubah jenis data kategorikal menjadi data numerik yang dapat dipahami model pada Gambar 5.

Cleaned_Tweets	Sentiment
ini manfaat uu cipta kerja iklim investasi indonesia ciptakerja	1
urgensi uu cipta kerja mudah lapang kerja baru ciptakerja	1
penting uu cipta kerja indonesia ciptakerja	1
anak muda samarinda tolak uu cipta kerja mositidakpercaya mositidakpercyadpr mositidakpercyadpr mositidakpercyajokowi cabutuuciptakerja cabutomnibuslaw melawanadalahkunci janganmenyerah fyp anakmuda anaksamarinda samarinda aprilmelawan	1
ratus mahasiswa aksi demonstrasi tuntutan tolak uu cipta kerja depan gedung dpr ri kamis warna ricuh lengkap portal berita mahasiswa tolakciptakerja ciptakerja mahasiswademo	1
cabutuuciptakerja aktor jefri nichol ikut demo sama mahasiswa depan gedung dpr ri suara tolak uu ciptaker dan ratus mahasiswa laku aksi teatrical pasu tikus dalam gedung wakil rakyat senayan mositidakpercaya	1
makan ti lah cabutuuciptakerja	1
ciptakerja uumnerba turnkeyproject hilirisasisda dan banyak	1
aksi ratus mahasiswa tolak ciptaker dpr langsung siang hingga malam hari ciptakerja	-1
semangat adek mahasiswa suara terus benar mbok bantu doa moga apa yg kalian juang allah meridhoiaamiin sudahtidakpercaya cabutuuciptakerja	1

Gambar 5. Data setelah proses label encoding

Evaluasi Model

Evaluasi performa model dilakukan secara rinci untuk menentukan algoritma terbaik dalam mengklasifikasikan sentimen publik terhadap Omnibus Law menggunakan data Twitter. Evaluasi dilakukan melalui beberapa tahap yang terdiri dari pengujian sebelum tuning parameter, pemilihan parameter optimal dengan tuning menggunakan teknik oversampling (SMOTE) dan random undersampling, serta analisis waktu komputasi yang dibutuhkan.

Evaluasi Sebelum Tuning Parameter

Evaluasi awal dilakukan terhadap tiga algoritma, yaitu Support Vector Machine (SVM), Random Forest (RF), dan Multinomial Naive Bayes (MNB) tanpa modifikasi parameter atau proses tuning. Dataset dibagi ke dalam variasi ukuran pengujian (test size) yaitu 10%, 20%, 30%, dan 40%. Tabel 2 menjelaskan hasil evaluasi rinci sebelum dilakukan proses tuning parameter:

Tabel 2. Evaluasi model sebelum tuning parameter

Algoritma	Test Size	TP	TN	FP	FN	Akurasi (%)	Recall (%)	Precision (%)
Support Vector Machine (SVM)	10%	620	863	169	67	86.27	86.94	85.69
	20%	1978	1225	93	141	93.19	92.59	93.14
	30%	2928	1826	164	238	92.20	91.58	92.12
	40%	3881	2427	240	326	91.77	91.16	91.62
Random Forest	10%	577	897	135	110	85.75	85.45	85.06
	20%	1884	1093	187	273	87.00	85.49	86.37
	30%	2805	1642	287	422	86.00	85.13	86.02
	40%	3700	2158	421	595	85.00	84.08	84.91
Multinomial Naive Bayes	10%	584	886	146	103	85.51	85.43	84.79
	20%	2007	783	64	583	81.00	77.11	84.96
	30%	2997	1196	95	868	81.00	77.43	85.09
	40%	3994	1618	127	1135	82.00	77.84	85.29

Hasil evaluasi menunjukkan bahwa sebelum tuning, algoritma SVM memiliki performa terbaik dibandingkan algoritma lainnya dengan akurasi tertinggi di semua ukuran test size.

Evaluasi Setelah Tuning Parameter dan Teknik Resampling

Untuk meningkatkan performa model, dilakukan tuning parameter dan penerapan teknik resampling seperti SMOTE untuk oversampling dan Random Undersampling. Hasil evaluasi rinci setelah proses tuning ditunjukkan pada Tabel 3.

Tabel 3. Evaluasi model setelah tuning parameter SMOTE oversampling

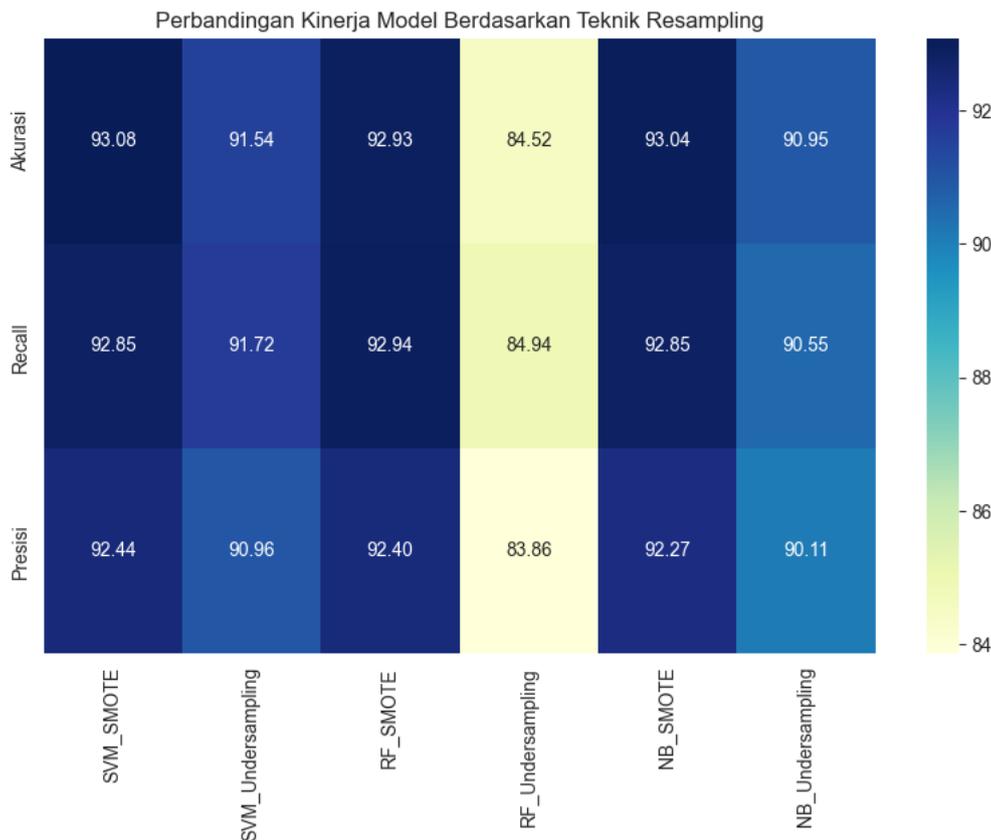
Algoritma	Test Size	Metode Tuning	TP	TN	FP	FN	Akurasi (%)	Recall (%)	Precision (%)
Support Vector Machine (SVM)	10%	SMOTE Oversampling	960	72	48	639	93.02	93.01	92.56
	20%	SMOTE Oversampling	1913	150	93	1281	92.93	92.98	92.44
	30%	SMOTE Oversampling	2877	218	167	1894	92.53	92.43	92.1
	40%	SMOTE Oversampling	3817	310	229	2518	92.16	92.07	91.69
	10%	SMOTE Oversampling	960	72	48	639	93.02	93.01	92.56
	20%	SMOTE Oversampling	1939	124	114	1260	93.08	92.85	92.37
	30%	SMOTE Oversampling	2902	193	166	1895	93.04	92.85	92.27
	40%	SMOTE Oversampling	3850	277	264	2483	92.91	92.73	91.77
Random Forest	10%	SMOTE Oversampling	969	63	52	635	93.1	93.16	92.94
	20%	SMOTE Oversampling	1919	144	114	1261	92.93	92.94	92.4
	30%	SMOTE Oversampling	2872	223	165	1896	92.47	92.39	92.02
	40%	SMOTE Oversampling	3829	298	259	2488	92.16	92.07	91.68
	10%	SMOTE Oversampling	960	72	48	639	93.02	93.01	92.56
	20%	SMOTE Oversampling	1913	150	93	1281	92.93	92.98	92.44
	30%	SMOTE Oversampling	2877	218	167	1894	92.53	92.43	92.1
	40%	SMOTE Oversampling	3817	310	229	2518	92.16	92.07	91.69
Multinomial Naive Bayes	10%	SMOTE Oversampling	960	72	48	639	93.02	93.01	92.56
	20%	SMOTE Oversampling	1939	124	114	1260	93.08	92.85	92.37
	30%	SMOTE Oversampling	2902	193	166	1895	93.04	92.85	92.27
	40%	SMOTE Oversampling	3850	277	264	2483	92.91	92.73	91.77
	10%	SMOTE Oversampling	969	63	52	635	93.1	93.16	92.94
	20%	SMOTE Oversampling	1919	144	114	1261	92.93	92.94	92.4

Algoritma	Test Size	Metode Tuning	TP	TN	FP	FN	Akurasi (%)	Recall (%)	Precision (%)
	30%	SMOTE Oversampling	2872	223	165	1896	92.47	92.39	92.02
	40%	SMOTE Oversampling	3829	298	259	2488	92.16	92.07	91.68

Tabel 4. Evaluasi model setelah tuning parameter random undersampling

Algoritma	Test Size	Metode Tuning	TP	TN	FP	FN	Akurasi (%)	Recall (%)	Precision (%)
Support Vector Machine (SVM)	10%	Random Undersampling	639	960	72	48	93.02	93.02	92.56
	20%	Random Undersampling	1281	1913	150	93	92.93	92.98	92.44
	30%	Random Undersampling	1911	2822	273	150	91.79	91.95	91.22
	40%	Random Undersampling	2544	3749	378	203	91.54	91.72	90.96
	10%	Random Undersampling	627	950	82	60	91.74	91.66	91.25
	20%	Random Undersampling	1263	1897	166	111	91.94	91.94	91.42
	30%	Random Undersampling	1864	2875	220	197	91.21	91.67	91.52
	40%	Random Undersampling	2475	3756	371	272	90.95	90.55	90.11
Random Forest	10%	Random Undersampling	594	921	111	105	87.43	86.98	86.87
	20%	Random Undersampling	1164	1727	336	210	84.11	84.21	83.38
	30%	Random Undersampling	1788	2573	522	273	84.58	84.94	89.05
	40%	Random Undersampling	2391	3419	708	356	84.52	84.94	83.86
Multinomial Naive Bayes	10%	Random Undersampling	639	960	72	48	93.02	93.02	92.56
	20%	Random Undersampling	1281	1913	150	93	92.93	92.98	92.44
	30%	Random Undersampling	1911	2822	273	150	91.79	91.95	91.22
	40%	Random Undersampling	2544	3749	378	203	91.54	91.72	90.96
	10%	Random Undersampling	627	950	82	60	91.74	91.66	91.25
	20%	Random Undersampling	1263	1897	166	111	91.94	91.94	91.42
	30%	Random Undersampling	1864	2875	220	197	91.21	91.67	91.52
	40%	Random Undersampling	2475	3756	371	272	90.95	90.55	90.11
	10%	Random Undersampling	594	921	111	105	87.43	86.98	86.87
	20%	Random Undersampling	1164	1727	336	210	84.11	84.21	83.38
	30%	Random Undersampling	1788	2573	522	273	84.58	84.94	89.05
	40%	Random Undersampling	2391	3419	708	356	84.52	84.94	83.86

Tabel 4 menampilkan hasil evaluasi model setelah diterapkan Random Undersampling sebagai teknik resampling. SVM masih menunjukkan performa terbaik dengan akurasi tertinggi dibanding model lainnya, meskipun sedikit menurun dibanding hasil dengan SMOTE. Random Forest memiliki akurasi yang lebih rendah dan cenderung kurang stabil dibanding SVM. Multinomial Naïve Bayes (MNB) memiliki hasil cukup baik, tetapi tetap lebih rendah dibanding SVM. Secara keseluruhan, Random Undersampling memang membantu menyeimbangkan data, namun tidak meningkatkan akurasi secara signifikan dibanding metode SMOTE.



Gambar 6. Perbandingan kinerja model berdasarkan teknik resampling

Untuk memperjelas perbandingan kinerja model secara visual, Gambar 6 menyajikan heatmap yang menunjukkan metrik akurasi, recall, dan presisi dari masing-masing model klasifikasi berdasarkan dua pendekatan resampling, yaitu SMOTE dan Random Undersampling. Berdasarkan visualisasi tersebut, SVM dengan SMOTE tampil sebagai model terbaik di semua metrik evaluasi, dengan akurasi sebesar 93,08%, recall 92,85%, dan presisi 92,44%. Sementara itu, Random Forest dan Multinomial Naive Bayes juga menunjukkan peningkatan performa setelah penerapan SMOTE, namun tidak secara konsisten melampaui performa SVM. Teknik Random Undersampling menghasilkan nilai metrik yang lebih rendah, khususnya pada model Random Forest yang menunjukkan presisi paling rendah yaitu 83,86%. Hal ini menunjukkan bahwa teknik SMOTE lebih efektif dalam mempertahankan informasi dari data minoritas. Oleh karena itu, penggunaan teknik resampling yang tepat sangat berpengaruh terhadap kualitas model klasifikasi, terutama pada dataset dengan distribusi kelas yang tidak seimbang.

Tabel 5 menunjukkan hasil evaluasi setelah model dituning dengan SMOTE Oversampling dan Random Undersampling. Dari hasil ini, SVM masih menjadi model dengan akurasi terbaik, terutama setelah menggunakan SMOTE, meskipun butuh waktu lebih lama untuk diproses. Random Forest juga mengalami peningkatan akurasi setelah tuning, tapi tetap di bawah SVM. Sementara itu,

Multinomial Naïve Bayes (MNB) memiliki waktu eksekusi paling cepat, namun akurasi lebih rendah dibanding dua model lainnya. Secara umum, SMOTE lebih efektif dalam meningkatkan performa model dibanding Random Undersampling, tapi membutuhkan waktu komputasi lebih lama.

Tabel 5. Evaluasi model berdasarkan waktu eksekusi

Model	Execution Time (minutes:seconds)
SVM (Before)	4:52.70
Random Forest (Before)	3:48.00
Multinomial Naive Bayes (Before)	0:03.60
SVM (Tuning SMOTE)	27:54.70
SVM (Random Undersampling)	25:43.50
Random Forest (Tuning SMOTE)	22:10.20
Random Forest (Random Undersampling)	20:55.30
Multinomial Naive Bayes (Tuning SMOTE)	0:18.40
Multinomial Naive Bayes (Random Undersampling)	0:15.20

KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma Support Vector Machine (SVM) dengan penerapan teknik resampling SMOTE memberikan performa terbaik dalam klasifikasi sentimen publik terhadap Omnibus Law di Twitter, dengan akurasi mencapai 93,08%, recall 92,85%, dan precision 92,44%. Hasil ini mengungguli algoritma Random Forest dan Multinomial Naïve Bayes, baik dalam evaluasi sebelum maupun sesudah tuning. Teknik SMOTE terbukti lebih efektif daripada Random Undersampling dalam menangani ketidakseimbangan data dan mempertahankan informasi dari kelas minoritas. Kontribusi utama dari penelitian ini adalah validasi bahwa pemilihan kombinasi algoritma dan strategi balancing yang tepat secara signifikan meningkatkan kinerja klasifikasi sentimen berbasis teks sosial. Penelitian ini juga menguatkan peran analisis lexicon-based sebagai pendekatan pelabelan yang andal untuk data besar ketika pelabelan manual tidak memungkinkan. Ke depan, pengembangan dapat diarahkan pada penerapan model berbasis deep learning seperti BERT atau LSTM, serta integrasi fitur geospasial untuk menganalisis distribusi opini publik secara wilayah. Selain itu, pendekatan semi-supervised learning dapat digunakan untuk memaksimalkan pemanfaatan data tak berlabel.

REFERENSI

- Adnyana, I. G. N. D., Adams, F., & Oktavia, A. W. (2021). *Analisis sentimen terhadap Undang-Undang Cipta Kerja menggunakan metode Naïve Bayes*. Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA), Jakarta, Indonesia.
- Azhari, M., Situmorang, Z., & Rosnelly, R. (2021). Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes. *Jurnal Media Informatika Budidarma*, 5(2), 640. <https://doi.org/10.30865/mib.v5i2.2937>
- Dwitiyanti, N., & Selvia, N. (2021). Analisis Sentimen Twitter Kebiasaan New Normal. *Seminar Nasional Riset dan Inovasi Teknologi (SEMNAS RISTEK)*.
- Hadi Sasongko, K., & Meutia Hilda, A. (2024). Analisis Sentimen Terhadap Film “Dirty Vote” Pada Media Sosial X dan Youtube dengan Algoritma Naive Bayes dan SVM. *Journal of Computer System and Informatics (JoSYC)*. <https://doi.org/10.47065/josyc.v6i1.6150>
- Istiqamah, N., & Rijal, M. (2024). Klasifikasi Ulasan Konsumen Menggunakan Random Forest dan SMOTE. *Journal of System and Computer Engineering (JSCE)*.
- Lee, R. S. T. (2024). *Natural Language Processing*. Singapore: Springer Nature Singapore. <https://doi.org/10.1007/978-981-99-1999-4>

- Makhtum, A. R., & Muhajir, M. (2023). Sentiment Analysis of Omnibus Law Using Support Vector Machine (Svm) With Linear Kernel. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 17(4), 2197–2206. <https://doi.org/10.30598/barekengvol17iss4pp2197-2206>
- Müller, A. C., & Guido, S. (2016). *Introduction to machine learning with Python: A guide for data scientists* (1st ed., D. Schanafelt, Ed.). O'Reilly Media, Inc.
- Pane, S. F., Owen, A., & Prianto, C. (2021). Analisis Sentimen UU Omnibus Law pada Twitter Menggunakan Metode Support Vector Machine. *Jurnal Telekomunikasi dan Komputer*, 11(2), 130. <https://doi.org/10.22441/incomtech.v11i2.10874>
- Prana, T., Sukma, W., & Pribadi, M. R. (2024). Analisis Sentimen Review Pengguna Viu pada Play Store dengan Algoritma Random Forest. *Journal of Software Engineering and Computational Intelligence (JSECI)*, 2(1).
- Sabrani, A., Gede Putu Wirarama Wedashwara, I. W., & Bimantoro, F. (2020). Metode Multinomial Naïve Bayes Untuk Klasifikasi Artikel Online Tentang Gempa Di Indonesia (Multinomial Naïve Bayes Method for Classification of Online Article About Earthquake in Indonesia). Diambil dari <http://jtika.if.unram.ac.id/index.php/JTIKA/>
- Sucahyo, N., Kurniati, I., Harvit, K., Studi, P., Informasi, S., Teknologi, F., & Jakarta, S. (2020). Analisis Sentimen Masyarakat Terhadap Uu Cipta Kerja Pada Media Sosial Twitter. *Jurnal Rekayasa Informasi SWADHARMA (JRIS)*.
- Syukron, A., Saputro, E., & Widodo, P. (2023). Penerapan Metode Smote Untuk Mengatasi Ketidakseimbangan Kelas Pada Prediksi Gagal Jantung. *Jurnal Teknologi Informasi dan Terapan (JTIT)* (Vol. 10). Diambil dari <https://doi.org/10/25047/jtit.v10i1.312>
- Wang, Y., Guo, J., Yuan, C., & Li, B. (2022). Sentiment Analysis of Twitter Data. *Applied Sciences (Switzerland)*, 12(22). <https://doi.org/10.3390/app122211775>
- Wankhade, M., Rao, A. C. S., & Kulkarni, C. (2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, 55(7), 5731–5780. <https://doi.org/10.1007/s10462-022-10144-1>