Analisis Sentimen Masyarakat Indonesia terhadap Coretax DJP di Twitter Menggunakan Algoritma Naïve Bayes

Nurul Khairunnisa[1*], Faiz Ahyaningsih[2]
[1,2] Matematika, Universitas Negeri Medan, Kota Medan, 20221, Indonesia
*Corresponding Author: nurul4211230015@mhs.unimed.ac.id

Abstrak

Coretax DJP merupakan sistem administrasi perpajakan terbaru yang diluncurkan oleh Direktorat Jenderal Pajak (DJP) sebagai upaya modernisasi layanan perpajakan di Indonesia. Implementasi sistem ini menimbulkan beragam tanggapan dari masyarakat, khususnya di media sosial Twitter. Penelitian ini bertujuan untuk menganalisis sentimen masyarakat Indonesia terhadap Coretax DJP serta mengevaluasi performa algoritma Naïve Bayes dalam melakukan klasifikasi sentimen. Data yang digunakan berupa cuitan Twitter terkait Coretax DJP. Untuk mengatasi ketidakseimbangan data, digunakan metode Synthetic Minority Over-sampling Technique (SMOTE). Hasil analisis menunjukkan bahwa sentimen masyarakat Indonesia terhadap Coretax DJP didominasi oleh sentimen netral sebesar 52,9%, diikuti oleh sentimen negatif sebesar 24,7% dan sentimen positif sebesar 22,4%. Evaluasi performa algoritma Naïve Bayes setelah penerapan SMOTE menghasilkan accuracy, precision, recall, dan F1-score rata-rata berbobot sebesar 77%.
Kata kunci: Analisis Sentimen; Coretax DJP; Twitter; Naïve Bayes; SMOTE.

Abstract

Coretax DJP is the latest tax administration system launched by the Directorate General of Taxes (DJP) as part of efforts to modernize tax services in Indonesia. The implementation of this system has generated various responses from the public, particularly on social media platform Twitter. This study aims to analyze public sentiment in Indonesia toward Coretax DJP and to evaluate the performance of the Naïve Bayes algorithm in sentiment classification. The dataset used consists of tweets related to Coretax DJP. To address data imbalance, the Synthetic Minority Over-sampling Technique (SMOTE) was applied. The results show that public sentiment toward Coretax DJP is dominated by neutral sentiment at 52.9%, followed by negative sentiment at 24.7% and positive sentiment at 22.4%. The evaluation of the Naïve Bayes algorithm after applying SMOTE achieved weighted average accuracy, precision, recall, and F1-score of 77%.
Keywords: *Sentiment Analysis, Coretax DJP, Twitter, Naïve Bayes, SMOTE*.

Citation: Khairunnisa, N. & Ahyaningsih, F. (2025). Analisis Sentimen Masyarakat Indonesia terhadap Coretax DJP di Twitter Menggunakan Algoritma Naïve Bayes. *Prodising Seminar Nasional Jurusan Matematika 2025*. 822 – 829.

PENDAHULUAN

Perkembangan teknologi internet telah membawa perubahan signifikan pada pola komunikasi masyarakat modern. Internet tidak lagi hanya berfungsi sebagai sumber informasi, melainkan juga menjadi ruang interaksi yang mendorong munculnya berbagai platform digital, salah satunya media sosial, yang memainkan peran strategis dalam penyebaran informasi dan pembentukan opini publik (Ramdhania dkk., 2024). Di Indonesia, erdasarkan laporan *We Are Social* dan *Meltwater* tahun 2025, tercatat 143 juta pengguna media sosial, dengan 25,2 juta di antaranya aktif di Twitter. Fitur *retweet* dan dominasi konten berbasis teks, menjadikan twitter sebagai *platform* yang efektif untuk menangkap opini Masyarakat secara *real-time*, sekaligus memudahkan pengolahan data menggunakan teknik *text mining* (Wongkar dan Angdresey, 2020). Struktur data yang terbuka, keberadaan hastag, serta dukungan API (*Application Programming Interface*) semakin memperkuat posisi twitter sebagai sumber data ideal dalam analisis persepsi public terhadap kebijakan pemerintah (Villavicencio dkk., 2021).

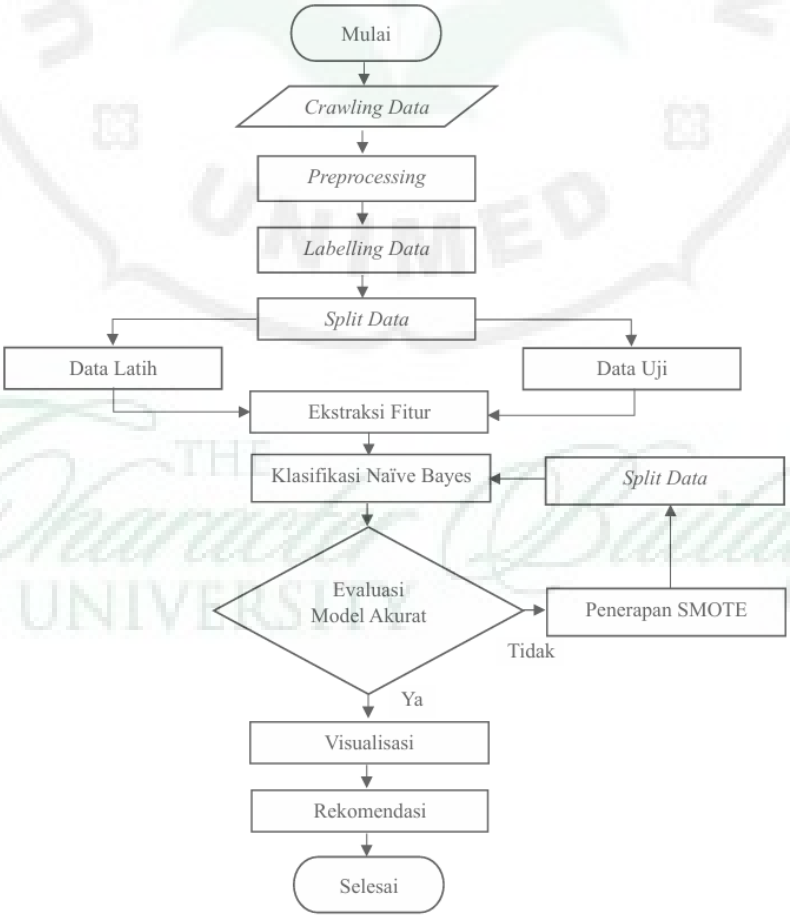
Salah satu kebijakan yang tengah menjadi sorotan publik dalam implementasi Coretax DJP, sistem administrasi perpajakan baru yang mulai diberlakukan sejak 1 Januari 2025. Coretax DJP dirancang untuk memodernisasi layanan perpajakan, meningkatkan transparansi, dan memberikan kemudahan bagi wajib pajak dalam berbagai proses administrasi (Panjaitan dan Yuna, 2024). Peningkatan jumlah wajib pajak terdaftar hingga 86,7 juta pada akhir 2024, menunjukkan kebutuhan akan sistem administrasi perpajakan yang semakin efisien. Namun demikian, berbagai keluhan muncul di media sosial, terutama twitter, terkait kendala akses, *error* sistem, kesulitan adaptasi, serta minimnya sosialisasi fitur. Kondisi ini menegaskan pentingnya analisis mendalam mengenai persepsi masyarakat terhadap Coretax DJP. Analisis sentimen telah menjadi pendekatan populer untuk memahami opini publik secara sistematis. Metode ini memungkinkan peneliti mengidentifikasi perasaan atau sikap pengguna terhadap suatu topik melalui data teks (Villavicencio dkk., 2021).Berbagai penelitian menunjukkan bahwa algoritma Naïve Bayes mampu memberikan performa yang baik dalam klasifikasi sentimen. (Negara dkk., 2024) membuktikan efektivitasnya dalam mengklasifikasikan komentar media sosial ke dalam tiga polaritas. (Qahar dkk., 2024) menggabungkan Naïve Bayes dan SVM dengan SMOTE untuk meningkatkan performa pada data yang tidak seimbang. Penelitian lain oleh (Ressan & Hassan, 2022), (Jonathan dan Nataliani, 2022),

serta (Fauzi dkk., 2023) juga memperkuat temuan bahwa Naïve Bayes memiliki akurasi tinggi dan efisiensi komputasi yang baik dalam berbagai konteks isu publik. Meskipun demikian, kajian mengenai sentimen masyarakat Indonesia terhadap Coretax DJP masih sangat terbatas, sehingga ruang penelitian pada topik ini masih terbuka luas.

Kebaruan ilmiah (*novelty*) penelitian ini terletak pada penerapan algoritma Naïve Bayes untuk mengidentifikasi kecenderungan sentimen masyarakat Indonesia terhadap implementasi sistem perpajakan modern Coretax DJP menggunakan data twitter. Tidak terdapat penelitian sebelumnya yang secara spesifik menganalisis respons publik terhadap Coretax DJP menggunakan pendekatan analisis sentimen berbasis *machine learning*. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi baru pada kajian literatur terkait respons masyarakat terhadap inovasi digital di bidang perpajakan. Berdasarkan kondisi tersebut, permasalahan utama dalam penelitian ini adalah bagaimana pola sentimen masyarakat Indonesia terhadap Coretax DJP serta bagaimana performa algoritma Naïve Bayes dalam mengklasifikasikan sentimen tersebut. Penelitian ini bertujuan untuk (1) menganalisis sentimen publik terhadap Coretax DJP berdasarkan data Twitter, dan (2) mengevaluasi performa algoritma Naïve Bayes dalam proses klasifikasi sentimen tersebut. Temuan penelitian ini diharapkan dapat membantu pemerintah dalam mengevaluasi tingkat penerimaan masyarakat terhadap Coretax DJP serta mendukung upaya perbaikan kualitas implementasinya.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif yang bertujuan untuk menganalisis sentimen masyarakat Indonesia terhadap *Coretax DJP* di Twitter dengan menggunakan algoritma *Naïve Bayes*. Pendekatan kuantitatif digunakan karena penelitian ini berfokus pada perhitungan numerik dalam mengklasifikasikan data sentimen ke dalam polaritas positif, negatif, atau netral. Data yang digunakan merupakan data sekunder yang diperoleh dengan cara *crawling data* dari Twitter menggunakan Twitter API pada Google Colab dengan rentang waktu selama 3 bulan, yaitu dari bulan Februari hingga April. Data yang digunakan berupa postingan bahasa Indonesia dengan kata kunci "*Coretax*". Tahapan yang dilakukan pada penelitian ini dapat dijelaskan pada gambar 1.



Gambar 1. Diagram Alir Penelitian

Crawling merupakan teknik yang digunakan untuk mengumpulkan data pada sebuah *website* dengan cara memasukkan URL (*Uniform Resource Locator*) sebagai acuan untuk mengidentifikasi *hyperlink* pada *website* tersebut.

Crawling data diambil dalam bentuk teks yang merupakan *tweet* dari pengguna Twitter. Data dikumpulkan berdasarkan kata kunci "*coretax*" dengan tweet berbahasa Indonesia dari tanggal 1 Februari 2025 sampai 30 April 2025. *Text preprocessing* diperlukan untuk mengubah data dokumen teks yang tidak terstruktur menjadi data yang terstruktur (Amal, 2023). Tahap dalam melakukan *text preprocessing*, antara lain *cleaning, case folding, slang word replacement, tokenization, stop word removal, stemming, dan detokenization. Labelling data* adalah proses memberikan kategori atau kelas berdasarkan sentimen (positif, negatif, atau netral) pada setiap dokumen dalam dataset. Pelabelan data dilakukan secara otomatis menggunakan *library python*, yaitu *TextBlob. TextBlob* bekerja dengan memberikan nilai polaritas dan subjektivitas pada sebuah teks, di mana saat klasifikasi adalah positif yang berarti nilai polaritas antara 0.0 sampai 1.0, kemudian netral apabila nilai polaritasnya adalah 0.0, dan terakhir negatif apabila nilai polaritasnya antara 0.0 sampai -1.0 (Parlika dkk., 2020).

Split data adalah tahap membagi data yang telah dilabel menjadi data latih dan data uji. Data latih digunakan untuk melatih model dalam menentukan kelas yang tepat. Sedangkan data yang akan diklasifikasikan berdasarkan model yang dibentuk sebelumnya sehingga algoritma klasifikasi dapat dievaluasi (Purnamasari dkk., 2023). Pembagian data dalam penelitian ini dilakukan dengan proporsi 80% untuk data latih dan 20% untuk data uji. Ekstraksi fitur bertujuan untuk mengubah data teks menjadi bentuk numerik yang bermakna sehingga model dapat mengolah dan mengenali pola dari data tersebut. Metode yang digunakan untuk ekstraksi fitur adalah *Term Frequency-Inverse Document Frequency* (TF-IDF). TF-IDF dihitung menggunakan rumus berikut (Fauzi dkk., 2023) :

$$W_{ad} = TF_{ad} \times log \frac{D}{DF_a} \quad (1)$$

Algoritma Naïve Bayes akan belajar dari data latih untuk memprediksi label sentimen pada data uji. Proses perhitungan dengan algoritma Naïve Bayes dimulai dengan menghitung probabilitas prior, probabilitas fitur, dan probabilitas posterior. Metode evaluasi yang digunakan adalah *confusion matrix*, yaitu sebuah tabel yang membandingkan hasil prediksi model dengan kelas sebenarnya dari data uji. Melalui *confusion matrix*, kinerja model dapat dianalisis menggunakan beberapa metrik, di antaranya *accuracy, precision, recall*, dan *F1-Score*. Dalam proses *crawling* data dari media sosial, seringkali terjadi ketidakseimbangan kelas data (*class imbalance*), yaitu kondisi di mana jumlah data pada salah satu kelas jauh lebih banyak dibanding kelas lainnya. Ketidakseimbangan ini menyebabkan model cenderung lebih akurat dalam mengenali kelas mayoritas, namun memiliki performa rendah pada kelas minoritas. Salah satu pendekatan untuk menangani kasus kelas yang tidak seimbang adalah *Synthetic Minority Over-sampling Technique* (SMOTE) (Candra et al., 2024).

Dalam proses visualisasi, digunakan dua cara, yaitu dengan *wordcloud* dan *pie chart. Wordcloud* digunakan untuk memvisualisasikan kata-kata yang sering muncul dalam data sentimen, *Pie chart* digunakan untuk memvisualisasikan persentase hasil klasifikasi sentimen (positif, negatif, dan netral). Berdasarkan pola sentimen yang ditemukan, rekomendasi akan diberikan guna meningkatkan pemahaman terhadap faktor-faktor yang mempengaruhi persepsi masyarakat, baik yang bersifat positif maupun negatif. Selain itu, hasil analisis ini juga dapat menjadi dasar dalam menyusun strategi komunikasi yang lebih efektif bagi Direktorat Jenderal Pajak (DJP), khususnya dalam meningkatkan citra dan penerimaan *Coretax* di media sosial.

HASIL DAN PEMBAHASAN

Data yang diperoleh dengan cara crawling di twitter dari Februari hingga April berjumlah 7600 tweet, yang terdiri dari 15 kolom, yaitu *conversation_id_str* sebagai ID percakapan, *created_at* menunjukkan waktu *tweet* dibuat, *favorite_count* adalah jumlah suka, *full_text* merupakan isi lengkap *tweet*, dan *id_str* sebagai ID unik *tweet*, kolom *image_url* memuat tautan gambar jika ada, *in_reply_to_screen_name* menunjukkan nama pengguna yang dibalas, *lang* adalah bahasa *tweet*, *location* menunjukkan lokasi pengguna, *quote_count*, *reply_count,* dan *retweet_count* mencatat jumlah kutipan, balasan, dan *retweet* yang diterima, *tweet_url* adalah tautan langsung ke *tweet*, *user_id_str* merupakan ID unik pengguna, dan *username* adalah nama akun pengguna Twitter tersebut. Pada analisis sentimen, hanya menggunakan kolom *full_text* yang dijadikan data untuk mengetahui sentimen terhadap *coretax DJP*. Data-data tersebut berisi komentar positif, netral, dan negatif. Berikut contoh *tweet* positif, netral, dan negatif dari hasil *crawling*.

Tabel 1. Contoh Komentar Positif, Netral, dan Negatif

Komentar Positif	Komentar Netral	Komentar Negatif
Coretax makin ke sini makin gampang dipakai, suka deh!	@kring_pajak Pagi kak.... kak nanya ini kenapa lagi ya coretax... https://t.co/YoJipKyVSh	Tinggal upload sama lapor aja susah banget masuknya di laman spt coretax

@trrgedi98 Pinter. Seneng gua kalau ada Wajib Pajak yang taat begini. Registrasi Coretax cepet.	Sepertinya coretax baru dibenerinnya nanti pas jam kantor deh.	si coretax jam begadang error. jam lembur juga error. jam subuh juga error
Pajak bukan lagi beban! Dengan Coretax nikmati kemudahan dan kecepatan dalam pengelolaan pajak Anda. #Coretax #PajakBerkualitas @DitjenPajakRI #renjani https://t.co/pmeRvJtF3L	@kring_pajak halo kami mau buat pembetulan pegawai harian di DJP online kok NIK nya tidak ditemukan ya? di DJP yaa untuk 2024 soalnya bukan di coretax	Urusan teknologi sesepele ini aja DJP gagal membereskan tp gayanya Coretax kek menyelesaikan problem kekacauan dunia

Setelah tahap *crawling data,* selanjutnya dilakukan proses *text preprocessing* yaitu membersihkan dan menyiapkan data teks mentah agar lebih mudah dianalisis. Berikut ini Adalah tahapan-tahapan umum dalam *text preprocessing*; *Cleaning:* proses pembersihan teks dari karakter atau elemen yang tidak dibutuhkan. Ini dapat mencakup menghapus *URL, mention, hastag*, tanda baca, angka, dan spasi ganda; *Case Folding:* proses mengubah semua huruf pada data menjadi huruf kecil (lowercase) agar tidak terjadi redudansi; *Slang Word Replacement:* proses mengganti kata-kata tidak baku, singkatan, atau kata gaul dengan padanan kata baku agar lebih mudah dipahami oleh sistem. Proses ini menggunakan kamus slang (*slangword dictionary*); *Tokenization:* proses memecah kalimat menjadi unit-unit kata (token).*Stopword Removal:* Proses menghapus kata-kata umum yang tidak memiliki pengaruh signifikan terhadap analisis. *Stopword removal* pada penelitian ini menggunakan *dictionary* yang merupakan *corpus stopword* berbahasa Indonesia; *Stemming:* proses mengembalikan kata ke bentuk dasarnya dengan menghapus imbuhan untuk menyederhanakan analisis.; dan *Detokenization*: proses menggabungkan kembali kata-kata hasil tokenization menjadi satu kalimat.

Tabel 2. Hasil *Text Preprocessing* pada Beberapa Data

Teks	*Cleaning*	*Case Folding*	*Slang Word Replacement*	*Tokenization*	*Stopword Removal*	*Stemming*	*Detokenization*
@kring_pajak @xxxauroraaa Tadi gua juga gini akhirnya input manual satu satu masih banyak penyakitnya coretax inii kacauu	Tadi gua juga gini akhirnya input manual satu satu masih banyak penyakitnya coretax inii kacauu	tadi gua juga gini akhirnya input manual satu satu masih banyak penyakitn ya coretax inii kacauu	tadi saya juga begini akhirnya input manual satu per satu masih banyak penyakitnya coretax ini kacau	['tadi', 'saya', 'juga', 'begini', 'akhirnya', 'input', 'manual', 'satu', 'per', 'satu', 'masih', 'banyak', 'penyakitnya', 'coretax', 'ini', 'kacau']	['input', 'manual', 'satu', 'per', 'satu', 'banyak', 'penyakit nya', 'coretax', 'kacau']	['input', 'manual', 'satu', 'per', 'satu', 'banyak', 'penyakit', 'coretax', 'kacau']	input manual satu per satu banyak penyakit coretax kacau
@exsipient lgi gamau bergelut dgn coretax yg lemot itu	lgi gamau bergelut dgn coretax yg lemot itu	lgi gamau bergelut dgn coretax yg lemot itu	lagi tidak mau bergelut dengan coretax yang lambat itu	['lagi', 'tidak', 'mau', 'bergelut', 'dengan', 'coretax', 'yang', 'lambat', 'itu']	['bergelu t', 'coretax', 'lambat']	['gelut', 'coretax', 'lambat']	gelut coretax lambat
Sepertinya coretax baru dibenerinnya nanti pas jam kantor deh https://t.co/vrC 55CxEPT	Sepertinya coretax baru dibenerinnya nanti pas jam kantor deh	sepertinya coretax baru dibenerin nya nanti pas jam kantor deh	sepertinya coretax baru diperbaikinya nanti saat jam kantor deh	['sepertinya', 'coretax', 'baru', 'diperbaikiny a', 'nanti', 'saat', 'jam', 'kantor', 'deh']	['coretax' , 'diperbai kinya', 'jam', 'kantor']	['coretax', 'perbaiki', 'jam', 'kantor']	coretax perbaiki jam kantor

Setelah proses *text preprocessing* selesai dilakukan, tahap berikutnya adalah pemberian label sentimen (*labelling*). Pemberian label ini bertujuan untuk mengklasifikasikan setiap teks ke dalam kategori positif, negatif, atau netral. Sebelum dilakukan *labelling*, kalimat hasil *detokenize* diterjemahkan ke dalam bahasa Inggris. Hal ini dikarenakan *library TextBlob* pada Python hanya dapat menganalisis teks berbahasa Inggris. Setelah teks berhasil diterjemahkan, proses *labelling* otomatis dilakukan menggunakan *TextBlob* yang menganalisis nilai polaritas. *TextBlob* menghitung polaritas sentimen dengan memanfaatkan *lexicon-based approach* melalui *pattern sentiment analyzer,* yaitu kamus leksikal berisi daftar kata yang telah diberi bobot polaritas dalam rentang -1 hingga +1. Nilai tersebut kemudian digunakan untuk menentukan label sentimen. Jika nilai polaritas > 0 maka sentimen dikategorikan positif. Jika polaritas < 0 dikategorikan negatif, dan jika polaritas bernilai 0, maka dikategorikan netral.

Tabel 3. Hasil Pelabelan Beberapa Data

Detokenization	Polaritas	Label Sentimen
coretax djp layan pajak lapor bayar integrasi sistem userfriendly update kini coretax djp implementasi	0,375	Positif
tinggal lapor susah masuk spt coretax	-0,5	Negatif
coretax operasional sistem dalam usaha aktivasi coretax	0	Netral
pintar senang wajib pajak taat coretax cepat	0,404762	Positif
si coretax jam begadang error jam lembur error jam subuh error	-0,5	Negatif

Sebelum proses klasifikasi, dilakukan *split data* menjadi data latih dan data uji. Data latih digunakan untuk membangun model prediksi dan data uji untuk evaluasi performansi dari model yang sudah dibangun. Pada proses klasifikasi, dilakukan optimasi dengan menerapkan SMOTE (*Synthetic Minority Over-sampling Technique*) dalam menangani data tidak seimbang. Jumlah data sebelum diterapkan SMOTE adalah 7600, yang terdiri dari 1703 positif, 1874 negatif, dan 4023 netral. Sedangkan saat diterapkan SMOTE, jumlah data menjadi 9567, yang terdiri dari 3189 positif, 3189 negatif, dan 3189 netral. Jumlah data dalam tiap kelas menjadi sama karena SMOTE secara sistematis menambah sampel sintetis pada kelas minoritas sampai ukurannya setara dengan kelas mayoritas sesuai target *sampling strategy* yang ditentukan, sehingga menghasilkan dataset yang seimbang dan mengurangi masalah kelas tidak seimbang pada proses klasifikasi. Perbandingan *split data* sebelum dan sesudah diterapkan SMOTE dapat dilihat pada tabel 4 berikut.

Tabel 4. *Split Data* Sebelum dan Sesudah SMOTE

Rasio	Proses Sebelum SMOTE		Proses Sesudah SMOTE	
80:20	*Training*	*Testing*	*Training*	*Testing*
	6080	1520	7653	1914
total	7600		9567	

Pada tahap ekstraksi fitur menggunakan TF-IDF pada persamaan (1), peneliti menggunakan 3 tweets sebagai contoh, antara lain; (D1) “woi coretax masih pagi udh error aja”; (D2) “Inovasi Coretax DJP sangat membantu meningkatkan kepatuhan pajak”; (D3) “Senin pagi bertengkar dengan Coretax”. Setelah dilakukan preprocessing, terdapat 11 kata standar dari 3 dokumen di atas, yaitu “coretax”, “pagi”, “error”, “inovasi”, “djp”, “bantu”, “tingkat”, “patuh”, “pajak”, “senin”, dan “tengkar”.

Tabel 5. Perhitungan TF-IDF Tiap Kata

Term	TF			DF	D/DF	IDF	(w)=TF×IDF		
	D1	D2	D3				D1	D2	D3
coretax	1	1	1	3	1	0	0,000	0,000	0,000
pagi	1	0	1	2	1,5	0,176	0,176	0,000	0,176
inovasi	0	1	0	1	3	0,477	0,000	0,477	0,000
djp	0	1	0	1	3	0,477	0,000	0,477	0,000
bantu	0	1	0	1	3	0,477	0,000	0,477	0,000
tingkat	0	1	0	1	3	0,477	0,000	0,477	0,000
patuh	0	1	0	1	3	0,477	0,000	0,477	0,000
pajak	0	1	0	1	3	0,477	0,000	0,477	0,000
senin	0	0	1	1	3	0,477	0,000	0,000	0,477
tengkar	0	0	1	1	3	0,477	0,000	0,000	0,477

Pada tahap klasifikasi menggunakan *Multinomial Naïve Bayes* yang merupakan supervised learning yang memprediksi kelas suatu anggota dengan probabilitas yang difokuskan untuk klasifikasi teks. Dimulai dengan menghitung probabilitas prior pada setiap label atau topik menggunakan persamaan

$$P(y_k) = \frac{N_k}{N} \quad (2)$$

Dimana: $P(y_k)$= probabilitas *prior* dari kelas y_k; N_k= jumlah sampel dalam kelas y_k; N= total jumlah sampel dalam *dataset.* Nilai dari probabilitas prior tersebut digunakan pada tahap pengujian. Pada tahap pengujian dilakukan perhitungan probabilitas fitur (kata) di suatu label dengan mempertimbangkan bobot (TF-IDF) dari kata tersebut. Rumus *Multinomial Naïve Bayes* yang digunakan untuk menghitung probabilitas fitur seperti pada persamaan

$$P(x_i|y_k) = \frac{N_{ik} + \alpha}{N_k + |v|} \quad (3)$$

Selanjutnya dilakukan perhitungan probabilitas posterior atau probabilitas suatu tweet masuk ke dalam suatu label dengan menggunakan persamaan

$$y = arg\ max_y P(y) \prod_{i=1}^{n} P(x_i|y) \quad (4)$$

Dimana; y = kelas yang akan diprediksi; $arg\ max_y$=mencari kelas *y* yang memiliki probabilitas tertinggi berdasarkan data fitur; $P(y)$ = probabilitas *prior;* $P(x_i|y)$ = probabilitas x_i muncul di kelas *y.*

Tabel 6. Klasifikasi Naïve Bayes

	Dokumen	Teks	Sentimen
Data Latih	1	coretax djp mudah wajib pajak administrasi digital	Positif
	2	tinggal lapor susah masuk spt coretax	Negatif
	3	coretax dibenerinnya jam kantor	Netral
	4	wajib error coretax senin pagi	Negatif
Data Uji	5	senin pagi tengkar coretax	?

Tahap pertama yaitu menghitung probabilitas tiap kelas menggunakan persamaan (2) sebagai berikut:$P(Pos) = \frac{1}{4} = 0{,}25$, $P(Neg) = \frac{2}{4} = 0{,}5$, $P(Net) = \frac{1}{4} = 0{,}25$.Setelah mendapatkan probabilitas dari kelas positif, negatif, dan netral, kemudian menghitung probabilitas setiap kata pada data uji yang akan dihitung menggunakan persamaan (3), sehingga diperoleh Tabel 7.

Tabel 7. Probality setiap kelas

	Positif	Negatif	Netral
P(senin|…)	0,04	0,069	0,045
P(pagi|…)	0,04	0,069	0,045
P(tengkar|…)	0,04	0,034	0,045
P(coretax|…)	0,08	0,103	0,091
P(…|d5)	1,28 x 10^{-6}	9,488 x 10^{-6}	2,134 x 10^{-6}

Nilai tersebut digunakan untuk menghitung data uji akan dikategorikan ke dalam kelas positif, negative, atau netral. Berdasarkan persamaan (4), diperoleh bahwa: $y(Neg|d5) > y(Net|d5) > y(Pos|d5)$. Dari hasil perhitungan, dapat dilihat bahwa nilai probabilitas sentimen negatif lebih besar dibandingkan sentimen netral dan positif, sehingga dokumen 5 yang berisi teks "senin pagi tengkar coretax" dikategorikan ke dalam kelas negatif. Data yang telah dibagi dengan rasio 80:20 kemudian diproses menggunakan algoritma Naïve Bayes. Proses klasifikasi dilakukan dengan bantuan bahasa pemrograman Python menggunakan library *Scikit-learn*. Tabel 7. berikut menyajikan ringkasan distribusi data sebelum dan sesudah dilakukan teknik penyeimbangan kelas menggunakan SMOTE.

Tabel 8. Distribusi Data Sebelum dan Setelah SMOTE

Jenis Data	Data Sebelum SMOTE				Data Setelah SMOTE			
	Positif	Negatif	Netral	Jumlah	Positif	Negatif	Netral	Jumlah
Latih	1392	1499	3189	6080	2551	2551	2551	7653
Uji	311	375	834	1520	638	638	638	1914
Jumlah	1703	1874	4023	**7600**	3189	3189	3189	**9567**

Tabel di atas menunjukkan bahwa sebelum dilakukan SMOTE, data sentimen netral mendominasi dibandingkan kelas positif dan negatif. Hal ini dapat menimbulkan bias pada model karena ketidakseimbangan kelas. Setelah diterapkan SMOTE, setiap kelas memiliki jumlah data yang sama sehingga distribusi menjadi lebih seimbang. Selanjutnya, hasil klasifikasi dievaluasi menggunakan metrik *accuracy, precision, recall,* dan *f1-score* berdasarkan *confusion matrix.* Hasil evaluasi data sebelum SMOTE ditunjukkan pada Tabel 8. berikut.

Tabel 7. Hasil Klasifikasi Data Sebelum SMOTE

Confussion Matrix		*Actual*			*Accuracy*	*Precision*	*Recall*	*F-1 Score*
		Positif	Netral	Negatif				
Predicted	Positif	156	140	32	63%	64%	63%	63%
	Netral	101	565	106				
	Negatif	54	129	237				

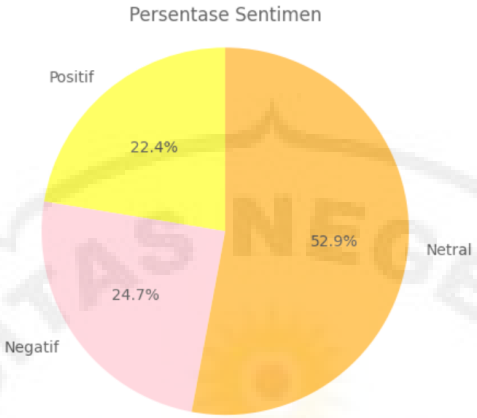
Sedangkan hasil klasifikasi setelah dilakukan SMOTE dapat dilihat pada Tabel 9. berikut.

Tabel 8. Hasil Klasifikasi Data Setelah SMOTE

Confussion Matrix		*Actual*			*Accuracy*	*Precision*	*Recall*	*F-1 Score*
		Positif	Netral	Negatif				
Predicted	Positif	510	115	27	77%	77%	77%	77%
	Netral	70	420	71				
	Negatif	58	103	540				

Berikut perhitungan *confussion matrix* setelah SMOTE untuk setiap sentiment; precison positif (79,9%); precison netral (65,8%); dan precison negative (84,6%), sehingga weighted avg precison (77%). Kemudian untuk *recall positif* (78,2%); recall netral (74,8%), recall negative (77%), sehingga weighted avg recall (77%). Selanjutnya F-1 Score untuk positif (79%); netral (70%), negative (80%), sehingga weighted avg F1-score (77%), dengan demikian Tingkat *Accuracy (77%)*

Untuk memahami bagaimana persepsi masyarakat terhadap sistem administrasi perpajakan baru *Coretax DJP*, dilakukan analisis distribusi sentimen yang divisualisasikan dalam bentuk diagram lingkaran. Hasil analisis pada Gambar 4.2 menunjukkan bahwa sentimen netral mendominasi dengan proporsi 52,9%, diikuti sentimen negatif sebesar 24,7%, dan sentimen positif sebesar 22,4%.



Gambar 2. Persentase Sentimen Masyarakat Indonesia terhadap Coretax DJP di Twitter

Dominasi sentimen netral ini mengindikasikan bahwa sebagian besar pengguna Twitter menyampaikan komentar yang bersifat informatif atau sekadar menyebutkan pengalaman tanpa memuat ekspresi emosional yang kuat, baik dalam bentuk keluhan maupun apresiasi. Sementara itu, keberadaan sentimen negatif yang lebih tinggi dibandingkan positif menunjukkan bahwa masih terdapat sejumlah kendala dalam implementasi *Coretax DJP*. Namun, di sisi lain, sentimen positif tetap muncul, terutama pada aspek kemudahan pelaporan dan dukungan layanan yang dirasakan sebagian pengguna. Berikut adalah *wordcloud* untuk kata-kata yang paling sering muncul pada masing-masing kategori sentimen.



Gambar 3. Wordcloud Sentimen Positif, Netral, dan Negatif

Berdasarkan hasil analisis sentimen masyarakat terhadap sistem administrasi perpajakan *Coretax DJP* di Twitter, terdapat beberapa rekomendasi yang dapat diberikan kepada Direktorat Jenderal Pajak (DJP) dalam rangka meningkatkan kualitas pelayanan:Banyaknya keluhan masyarakat terkait "akses Coretax", "alami kendala", dan "*error*" menunjukkan bahwa aspek teknis sistem masih perlu diperbaiki. Oleh karena itu, diperlukan peningkatan kapasitas server, optimalisasi performa sistem, serta uji coba ketahanan (*stress testing*) sebelum periode pelaporan pajak massal berlangsung. Kata-kata seperti "hai kakak" dan "mohon maaf" sering muncul pada seluruh kategori sentimen, yang mengindikasikan tingginya intensitas interaksi wajib pajak dengan admin layanan DJP. Disarankan agar DJP memperkuat kapasitas tim *helpdesk,* baik dari sisi jumlah petugas maupun kualitas respon, agar penyelesaian masalah wajib pajak dapat lebih cepat dan solutif. Kemunculan kata-kata seperti "lapor SPT", "faktur pajak", dan "akun Coretax" pada sentimen netral maupun positif menunjukkan bahwa sebagian besar pengguna masih berfokus pada aspek teknis penggunaan sistem. Unggahan atau komentar dengan kata-kata tersebut umumnya berupa pertanyaan, yang mengindikasikan adanya kebutuhan akan petunjuk yang lebih jelas. Oleh karena itu, DJP disarankan untuk menyediakan petunjuk penggunaan yang lengkap dan mudah diakses dari setiap layanan yang diberikan, seperti tata cara pelaporan SPT, pembuatan faktur pajak, serta penanganan kendala akun Coretax. Analisis sentimen masyarakat seperti yang dilakukan dalam penelitian ini dapat dijadikan sebagai alat monitoring berkelanjutan. Dengan melakukan analisis secara berkala, DJP dapat mengidentifikasi permasalahan utama yang dihadapi wajib pajak sekaligus menilai efektivitas perbaikan yang telah dilakukan.

KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa sentimen masyarakat Indonesia terhadap Coretax DJP di Twitter didominasi oleh sentimen netral sebesar 52,9%, diikuti sentimen negatif sebesar 24,7% dan sentimen positif sebesar 22,4%. Hal ini menunjukkan bahwa mayoritas masyarakat masih memberikan tanggapan yang bersifat informatif atau

deskriptif tanpa muatan emosi yang kuat, meskipun terdapat cukup banyak keluhan terkait kendala teknis penggunaan sistem. Algoritma *Naïve Bayes* ketika dikombinasikan dengan metode SMOTE mampu mengklasifikasikan sentimen masyarakat dengan akurasi mencapai 77%, serta nilai *precision, recall,* dan *f-1 score* rata-rata berbobot sebesar 77%, sehingga membuktikan bahwa Naïve Bayes cukup efektif dalam mengklasifikasikan sentimen masyarakat terhadap Coretax DJP apabila distribusi data lebih seimbang.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan dalam proses penelitian ini. Terima kasih disampaikan kepada dosen pembimbing yang telah memberikan arahan, masukan, serta bimbingan yang berharga selama penyusunan artikel ini. Penghargaan juga penulis sampaikan kepada rekan-rekan serta pihak terkait yang telah membantu dalam proses diskusi ilmiah, maupun peninjauan hasil penelitian. Tanpa dukungan dan bantuan dari berbagai pihak tersebut, penelitian ini tidak akan dapat terselesaikan dengan baik. Namun demikian, segala kekurangan dalam artikel ini sepenuhnya menjadi tanggung jawab penulis.

DAFTAR PUSTAKA

Amal, I. (2023). Perbandingan Pelabelan Otomatis Dan Manual Untuk Analisis Sentimen Terhadap Kenaikan Harga BBM Pertamina Pada Twitter Menggunakan Algoritma Support Vector Machine. Prosiding Seminar Nasional Mahasiswa Ilmu Komputer Dan Aplikasinya (SENAMIKA), 473–487. https://conference.upnvj.ac.id/index.php/senamika/article/view/2562/1952

Candra, Chandra, K. W., & Irsyad, H. (2024). Efektifitas SMOTE dalam Mengatasi Imbalanced Class Algoritma K-Nearest Neighbors pada Analisis Sentimen terhadap Starlink. Jurnal Ilmu Komputer Dan Informatika, 4(1), 31–42. https://doi.org/10.54082/jiki.132

Fauzi, F., Setiayani, W., Utami, T. W., Yulianto, E., & Harmoko, I. W. (2023). Comparison Of Random Forest and Naïve Bayes Classifier Methods in Sentiment Analysis on Climate Change Issue. BAREKENG: Jurnal Ilmu Matematika Dan Terapan, 17(3), 1439–1448. https://doi.org/10.30598/barekengvol17iss3pp1439-1448

Jonathan, M., & Nataliani, Y. (2022). Analisis Sentimen Penilaian Masyarakat Indonesia terhadap GeNose pada Komentar Youtube Menggunakan Metode Naïve Bayes. D'Cartesian: Jurnal Matematika Dan Aplikasi, 11(1), 1–8. https://ejournal.unsrat.ac.id/index.php/decartesian

Negara, E. S., Syaputra, R., Erlansyah, D., Andryani, R., Saksono, P. H., Aditya, F., & Agam, P. M. (2024). Sentiment Analysis of Public Opinion on Presidential Advisory Appointments Using Naive Bayes Classification. Jurnal Ilmiah Ilmu Terapan Universitas Jambi, 8(2), 452–466. https://doi.org/10.22437/jiituj.v8i2.35254

Panjaitan, M. R., & Yuna. (2024). Pengaruh Coretax terhadap Transparansi dan Akuntabilitas Sistem Perpajakan. Jurnal Riset Akuntansi, 2(4), 51–60. https://doi.org/10.54066/jura-itb.v2i3.2560

Parlika, R., Ilham Pradika, S., Hakim, A. M., & Kholilul, R. N. M. (2020). Analisis Sentimen Twitter Terhadap Bitcoin dan Cryptocurrency Berbasis Python TextBlob. JIFTI-Jurnal Ilmiah Teknologi Informasi Dan Robotika, 2(2), 33–37. https://t.co/QaUW3P2TKc

Purnamasari, D., Bayu, A., Desy, A., Fanka, W. A. P., Reza, A., Safrila, M., Yanda, O. N., & Hidayati, U. (2023). Pengantar Metode Analisis Sentimen. Gunadarma.

Qahar, M. Y. Al, Ruldeviyani, Y., Mukharomah, U. N., Fidyawan, M. A., & Putra, R. (2024). Factor Analysis Influencing Mobile JKN User Experience Using Sentiment Analysis. IAES International Journal of Artificial Intelligence, 13(2), 1782–1793. https://doi.org/10.11591/ijai.v13.i2.pp1782-1793

Ramdhania, K. F., Hidayat, D. F., & Salkiawati, R. (2024). Implementasi Metode Naïve Bayes dan Support Vector Machine (SVM) untuk Menganalisis Sentimen Pengguna Twitter terhadap Transjakarta. JMPM: Jurnal Matematika Dan Pendidikan Matematika, 9(1), 1–14. https://doi.org/10.26594/jmpm.v9i1.4494

Ressan, M. B., & Hassan, R. F. (2022). Naïve-Bayes Family for Sentiment Analysis During COVID-19 Pandemic and Classification Tweets. Indonesian Journal of Electrical Engineering and Computer Science, 28(1), 375–383. https://doi.org/10.11591/ijeecs.v28.i1.pp375-383

Villavicencio, C., Macrohon, J. J., Inbaraj, X. A., Jeng, J. H., & Hsieh, J. G. (2021). Twitter Sentiment Analysis Towards Covid-19 Vaccines in the Philippines Using Naïve Bayes. Information (Switzerland), 12(5). https://doi.org/10.3390/info12050204

Wongkar, M., & Angdresey, A. (2020). Sentiment Analysis Using Naive Bayes Algorithm of the Data Crawler: Twitter. IEEE Xplore. https://doi.org/10.1109/ICIC47613.2019.8985884.