



Penerapan SVM dan Regresi untuk Prediksi Intensitas Sentimen Pemilu Presiden Indonesia

Valen Rionald¹, Syafrial Fachri Pane^{2*}, Muhammad Yusril Helmi Setyawan³

^{1,2,3}Teknik Informatika, Universitas Logistik dan Bisnis Internasional,
Jl. Sariasih, Bandung 40151, Indonesia

*Email Penulis Koresponden: syafrial.fachri@ulbi.ac.id

Abstrak:

Dalam konteks pemilihan umum presiden Indonesia, analisis sentimen publik melalui media sosial merupakan alat yang penting untuk memahami persepsi dan reaksi masyarakat terhadap calon presiden dan kebijakan mereka. Studi ini mengembangkan model hybrid yang mengintegrasikan *Support Vector Machine* (SVM) dan *Ridge Regression*, menggunakan library BERT untuk memprediksi intensitas sentimen dari data Twitter. Pendekatan ini dirancang untuk mengatasi tantangan variabilitas ekspresi dan ambiguitas bahasa, yang sering kali mempersulit interpretasi data sentimen dengan tepat. Penelitian ini menggunakan teknik *preprocessing* yang komprehensif, termasuk pembersihan teks dan normalisasi data, serta penerapan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) untuk menangani ketidakseimbangan kelas dalam dataset. Hasil dari penelitian ini menunjukkan bahwa model *hybrid* dapat mencapai tingkat akurasi, presisi, recall, dan F1-Score yang tinggi dengan tiga rasio yang berbeda, menegaskan keefektifan model dalam mengklasifikasikan dan mengukur intensitas sentimen. Temuan menunjukkan bahwa kombinasi SVM dan regresi, didukung dengan analisis BERT, efektif dalam mengklasifikasikan dan mengukur intensitas sentimen secara akurat. Hasil intensitas yang dijelaskan pada gambar 11 untuk kandidat Anies Baswedan mayoritas sentimen adalah netral sebesar 53.1%. Selanjutnya, pada gambar 12 untuk kandidat Prabowo Subianto netral sebesar 63.5% dan gambar 13 untuk kandidat Ganjar Pranowo dengan 62.9%.

Kata Kunci:

Analisis Sentimen;
Machine Learning;
Pemilihan Umum;
Media Sosial;

Riwayat Artikel:

Diserahkan 24 Juli 2024
Direvisi 22 Agustus 2025
Diterima 26 Agustus 2025

DOI:

[10.22441/incomtech.v15i3.28525](https://doi.org/10.22441/incomtech.v15i3.28525)

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



1. PENDAHULUAN

Analisis sentimen dalam konteks pemilihan umum presiden Indonesia menjadi sangat relevan mengingat peran media sosial dan platform digital yang semakin mempengaruhi opini publik[1]. Sentimen publik, yang diungkapkan melalui berbagai media, menyediakan data berharga yang dapat menganalisis persepsi dan reaksi masyarakat terhadap kandidat dan kebijakan mereka[2]. Klasifikasi sentimen biasanya mencakup kategorisasi komentar sebagai positif, negatif, atau netral[3]. Namun, untuk mendapatkan kejelasan yang lebih dalam, perlu adanya analisis lebih lanjut yang bisa mengukur intensitas dan nuansa emosi yang lebih spesifik menggunakan model regresi[4]. Penggunaan teknik machine learning dalam analisis sentimen telah banyak dilakukan, tetapi masih jarang yang mengintegrasikan pendekatan klasifikasi dan regresi dalam model hybrid yang dapat memberikan wawasan lebih mendalam tentang data sentimen.

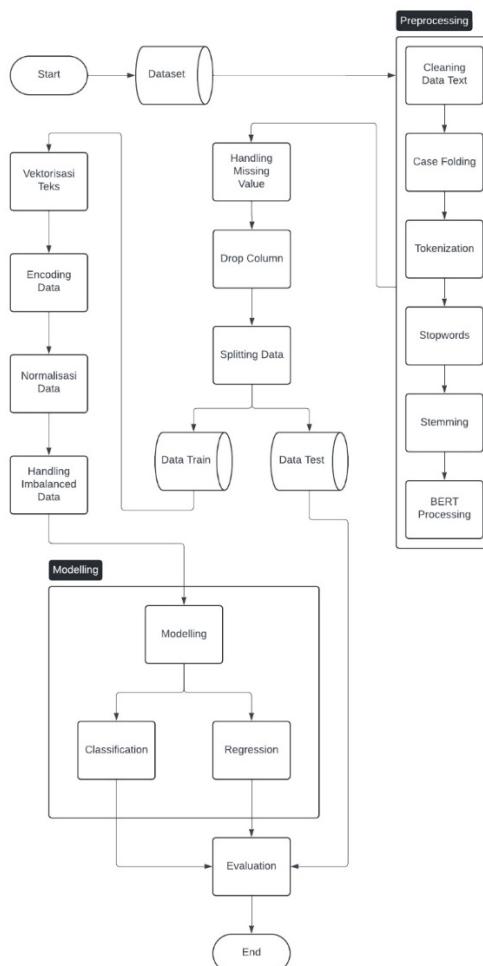
Pemilihan umum presiden di Indonesia pada tahun 2024 menunjukkan betapa pentingnya media sosial sebagai medan pertarungan opini publik[5]. Penelitian terbaru menemukan bahwa lebih dari 30,000 tweet telah dihasilkan mengenai tiga kandidat utama, yaitu Ganjar Pranowo, Prabowo Subianto, dan Anies Baswedan, yang masing - masing mendapatkan 10,000 tweet. Analisis ini menggunakan data dari April 2023, sebelum kampanye resmi dimulai, yang memberikan indikasi awal sentimen publik terhadap masing - masing kandidat[6]. Proses klasifikasi dan pengukuran intensitas sentimen yang efektif terkendala oleh variasi besar dalam ekspresi emosional dan ambiguitas bahasa, termasuk penggunaan ironi dan slang dalam komunikasi digital[7]. Hal ini menimbulkan tantangan dalam interpretasi yang akurat dan membutuhkan analisis yang komprehensif untuk menghindari kesalahan dalam pengambilan keputusan politik[8]. Kesulitan ini diperparah dengan biaya yang besar untuk pengolahan dan analisis data, menuntut solusi yang efisien dan efektif dalam menangani volume dan variabilitas data yang tinggi[9].

Studi – studi sebelumnya telah menunjukkan penggunaan berbagai model machine learning dalam analisis sentimen, terutama dalam konteks pemilihan umum. Misalnya, penelitian yang dilakukan oleh [10], [11], dan [12] telah mengeksplorasi efektivitas model *Bidirectional Encoder Representations from Transformers* (BERT) dan penelitian [13] telah melakukan eksplorasi *Long Short-Term Memory* (LSTM) untuk klasifikasi sentimen. Kedua model ini dikenal karena kemampuan mereka dalam *Natural Language Processing* (NLP), menjadikannya pilihan populer untuk analisis sentimen[14]. Lalu, walaupun lebih tradisional, model Naive Bayes Classifier menunjukkan performa yang baik pada penelitian[15]. Lebih lanjut, penelitian [16] dan [17] mengintegrasikan model regresi dalam sebuah pendekatan *hybrid*, menggunakan model seperti K-Nearest Neighbors (KNN) untuk mengukur intensitas sentimen. Pendekatan hybrid ini memungkinkan kombinasi dari klasifikasi dan pengukuran intensitas sentimen, memberikan gambaran yang lebih kaya tentang sentimen pemilih[18]. Temuan ini memberikan dasar untuk pengembangan model hybrid dalam penelitian ini, yang menggabungkan kekuatan model klasifikasi dan regresi untuk analisis yang lebih mendalam dan komprehensif terhadap sentimen pemilih dalam pemilihan umum presiden.

Kontribusi penelitian ini, model *hybrid* yang dikembangkan akan menggunakan kombinasi dari metode klasifikasi dan regresi untuk menilai sentimen terkait pemilihan umum presiden Indonesia. Model ini akan memanfaatkan teknik yang telah terbukti efektif dalam studi sebelumnya, seperti SVM untuk klasifikasi dan *Ridge Regression* untuk regresi serta menggunakan BERT untuk menghitung intensitas sentimen nya dengan menggunakan model dari pustaka *Hugging Face* untuk klasifikasi teks berbahasa Indonesia, menawarkan pendekatan yang komprehensif dan mendalam. Untuk melihat performa model maka menggunakan metrik klasifikasi seperti *precision*, *recall*, *f1-score*, dan *accuracy*. Selanjutnya, untuk regresi menggunakan metrik seperti RMSE, MSE, dan MAE.

2. METODE

Adapun metode penelitian yang digunakan pada penelitian ini dapat dilihat pada gambar 1 sebagai berikut.



Gambar 1. Metodologi Penelitian

Untuk menerapkan model *hybrid* klasifikasi dan regresi dalam konteks pemilihan umum untuk prediksi sentimen dan intensitas nya, terdapat beberapa tahapan sebagai berikut.

1. Mengumpulkan data yang relevan dengan objek penelitian. Data terdiri dari tiga data kandidat presiden, Anies Baswedan, Prabowo Subianto dan Ganjar Pranowo.
2. Melakukan analisis dan *cleaning data text* seperti membersihkan teks dari URL, *mentions*, *tags*, membuat teks menjadi huruf kecil, menghapus nomor dan tanda baca, tokenisasi teks, menghapus *stopwords*, melakukan *stemming* dan menghubungkan kembali teks untuk diolah lebih lanjut ke *modelling*. Setelah itu, menggunakan model BERT yang dapat membaca teks Bahasa Indonesia untuk menghitung skor intensitas nya yang kemudian dipecah menjadi tiga kolom, Positif, Netral dan Negatif. Hasil dari perhitungan tersebut kemudian dijadikan label untuk nilai yang tertinggi menjadi kategori sentimen Positif, Netral atau Negatif. Setelah itu, dilakukan proses normalisasi data untuk menyama ratakan rentang nilai setiap variabel. Diketahui bahwa data yang digunakan mengalami *imbalanced class*, dilakukan teknik *over-sampling* menggunakan SMOTE (*Synthetic Minority Over-Sampling Technique*). Setelah data seimbang, data dibagi menjadi dua yaitu data *training* untuk melakukan *training* model, dan data *testing* untuk melakukan *testing* model.
3. Data yang telah disiapkan, digunakan untuk pemodelan menggunakan model SVM dengan empat kernel untuk prediksi klasifikasi sentimen dan model Ridge Regression untuk prediksi intensitas sentimen.
4. Mengevaluasi model dari hasil prediksi yang menggunakan data *training* menggunakan evaluasi metrik (*accuracy*, *precision*, *recall*, *f1-score* dan *AUC*) dan *MAE*, *MSE*, *RMSE*, *MAPE* serta *R*² untuk evaluasi metrik regresi.

2.1 BERT

BERT (*Bidirectional Encoder Representations from Transformers*) adalah model pemrosesan bahasa alami yang dikembangkan oleh Google[19]. Model ini menggunakan teknik "*transformers*", khususnya "*attention mechanism*", yang memungkinkan model untuk memahami konteks kata dalam sebuah kalimat lebih efektif dibanding model sebelumnya. Salah satu keunggulan utama BERT adalah kemampuannya untuk melatih representasi kata yang kontekstual, dimana arti sebuah kata dapat berubah berdasarkan kata-kata di sekitarnya.

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (1)$$

Pada rumus (1) Q, K, V adalah *query*, *key*, dan *value matrices* yang terkait dengan kata – kata dalam kalimat, dan d_k adalah dimensi dari *key vectors*. Untuk BERT ini, digunakan model dari *Hugging Face* dengan nama model *bert-base-indonesian-1.5G-finetuned-sentiment-analysis-smsa* yang dibuat oleh *ayameRushia* dan merupakan hasil penyempurnaan dari model sebelumnya yang

bernama *bert-base-indonesian-1.5G* oleh *cahya* yang berfungsi untuk menghitung skor intensitas dari teks berbahasa Indonesia.

2.2. SVM

Support Vector Machine (SVM) adalah metode *machine learning* yang digunakan untuk klasifikasi dan regresi[20]. SVM bekerja dengan mencari *hyperplane* yang optimal untuk memisahkan data ke dalam kelas – kelas yang berbeda dengan margin terbesar. SVM mendukung penggunaan berbagai jenis kernel untuk memungkinkan pemisahan linier di ruang fitur yang lebih tinggi, khususnya ketika data tidak linier di ruang asli.

$$K(x_i, x_j) = x_i^T x_j \quad (2)$$

Pada rumus (2) adalah rumus SVM untuk kernel linear dimana x_i, x_j adalah vektor fitur untuk sampel data i dan j. $x_i^T x_j$ adalah produk dot antara dua vektor fitur, mengukur kesamaan linier antara kedua sampel.

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d \quad (3)$$

Pada rumus (3) adalah rumus SVM untuk kernel polynomial dimana γ adalah parameter skala yang menentukan seberapa jauh pengaruh titik data tunggal dalam proses pelatihan. r adalah koefisien yang menambahkan konstanta ke produk dot, memberikan fleksibilitas lebih dan d adalah derajat polinomial yang menentukan kompleksitas batas keputusan.

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right) \quad (4)$$

Pada rumus (4) adalah rumus SVM untuk kernel RBF (*Radial Basis Function*) dimana $\|x_i - x_j\|$ adalah norma euclidean (jarak) antara dua vektor fitur, mengukur seberapa jauh kedua titik tersebut dan γ adalah parameter yang mengatur seberapa cepat eksponensial akan menurun, memberikan kontrol atas pengaruh titik data individu terhadap keputusan.

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r) \quad (5)$$

Pada rumus (5) adalah rumus SVM untuk kernel sigmoid dimana γ adalah parameter skala yang menyesuaikan amplitudo dari hasil produk dot dan r termasuk bisa dalam perhitungan, memindahkan fungsi tangen hiperbolik ke kiri atau kanan.

2.3. Ridge Regression

Ridge Regression, juga dikenal sebagai *Tikhonov regularization*, adalah teknik regresi yang menambahkan penalti pada ukuran koefisien regresi untuk mengatasi masalah multikolinearitas dan overfitting [21]. Metode ini memperkenalkan istilah

regularisasi yang membantu mengurangi kompleksitas model dengan menjaga koefisien regresi tetap kecil.

$$\text{minimize} \left\{ \left| \left| y - X\beta \right| \right|^2 + \lambda \left| \left| \beta \right| \right|^2 \right\} \quad (6)$$

Pada rumus (6) y adalah vektor hasil observasi atau variabel dependen, X adalah matriks fitur atau variabel independen, β adalah vektor koefisien regresi yang dicari dan λ adalah parameter regularisasi, yang mengontrol kekuatan penalti terhadap koefisien regresi.

2.4. SMOTE (*Synthetic Minority Over-Sampling Technique*)

SMOTE adalah metode untuk mengatasi masalah ketidakseimbangan kelas dalam dataset, di mana satu kelas (minoritas) jauh lebih sedikit dibandingkan dengan kelas lainnya (majoritas)[22]. SMOTE bekerja dengan menghasilkan contoh sintetis dari kelas minoritas untuk meningkatkan jumlah sampel dalam kelas tersebut.

$$x_{new} = x_i + \lambda \cdot (x'_i - x_i) \quad (7)$$

Pada rumus (7) x_i adalah sampel minoritas dan x'_i adalah sampel minoritas tetangga terdekatnya (dalam jarak Euclidean), SMOTE menghasilkan titik sintetis baru x_{new} dimana x_i adalah titik data kelas minoritas, x'_i titik data tetangga terdekat dari kelas minoritas dan λ adalah parameter acak yang berada dalam rentang $[0, 1]$, yang menentukan seberapa jauh titik sintetis akan berada antara x_i dan x'_i .

2.5. Evaluasi Metrik

Efektivitas model hybrid dalam analisis sentimen dinilai dengan memeriksa nilai keakuratan dari model prediksi [23]. Untuk bagian klasifikasi, lima metrik perhitungan yang digunakan dalam mengevaluasi keakuratan ini mencakup *precision*, *recall*, *f1-score*, *accuracy*, dan AUC. Untuk bagian regresi, metrik yang digunakan meliputi *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *R-squared* (R^2).

2.5.1. *Precision*

Precision mengukur proporsi prediksi positif model yang benar - benar positif. Ini penting dalam konteks di mana biaya dari False Positive tinggi. Nilai *precision* juga berkisar antara 0 dan 1, di mana 0 menunjukkan tidak ada prediksi positif yang benar, dan 1 menunjukkan bahwa setiap prediksi positif adalah benar [24].

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (8)$$

Pada rumus (8) TP adalah kasus di mana model dengan benar memprediksi kelas positif dan FP (*False Positives*) adalah kasus di mana model salah memprediksi negatif sebagai positif.

2.5.2. Recall

Recall mengukur kemampuan model untuk menemukan semua kasus positif yang relevan dalam dataset. Ini berguna terutama dalam situasi di mana menghilangkan False Negatives sangat kritis. Seperti precision, recall juga memiliki rentang nilai dari 0 hingga 1, di mana 0 berarti tidak ada kasus positif yang terdeteksi, dan 1 menunjukkan bahwa semua kasus positif terdeteksi [25].

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (9)$$

Pada rumus (9) TP adalah kasus di mana model dengan benar memprediksi kelas positif dan FN (False Negatives) adalah kasus di mana model salah memprediksi positif sebagai negatif.

2.5.3. F1-Score

F1-Score sangat berguna ketika membutuhkan keseimbangan antara precision dan recall. F1-Score memiliki rentang nilai dari 0 hingga 1, di mana nilai mendekati 0 menunjukkan kinerja yang buruk (rendahnya *precision* dan/atau *recall*) seperti pada rumus (10), sedangkan nilai mendekati 1 menunjukkan kinerja yang optimal [26].

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

2.5.4. Accuracy

Accuracy adalah salah satu metrik yang paling umum dan mengukur proporsi prediksi yang benar terhadap total jumlah kasus. Nilainya berkisar dari 0 hingga 1, di mana 0 berarti tidak ada prediksi yang benar, dan 1 berarti semua prediksi benar [27].

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{Total Observations}} \quad (11)$$

Pada rumus (11) TP (*True Positive*) adalah kasus di mana model dengan benar memprediksi kelas positif, TN (*True Negative*) adalah kasus di mana model dengan benar memprediksi kelas negatif dan *Total Observations* adalah jumlah total sampel yang diuji.

2.5.5. AUC

Skor AUC menyatakan kemungkinan model mengklasifikasikan positif lebih tinggi daripada negatif secara acak untuk semua ambang klasifikasi yang mungkin. AUC adalah area di bawah kurva ROC, yang plot *True Positive Rate* (TPR) terhadap *False Positive Rate* (FPR) pada berbagai *threshold setting*.

$$AUC = \sum_{i=1}^{n-1} ((x_{i+1} - x_i) \cdot \frac{y_i + y_{i+1}}{2}) \quad (12)$$

Pada rumus (12) x_i dan x_{i+1} adalah nilai pada sumbu x untuk titik i dan titik i+1, yang merepresentasikan *False Positive Rate* (FPR). y_i dan y_{i+1} adalah nilai pada sumbu y untuk titik i dan titik i+1, yang merepresentasikan *True Positive Rate* (TPR).

2.5.6. MAE

MAE mengukur rata-rata magnitudo kesalahan dalam serangkaian prediksi, tanpa mempertimbangkan arahnya (positif atau negatif). MAE adalah rata-rata dari nilai absolut dari kesalahan antara prediksi dan nilai sebenarnya[28].

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

Pada rumus (13) y_i adalah nilai sebenarnya, \hat{y}_i adalah nilai prediksi, dan n adalah jumlah total observasi.

2.5.7. MSE

MSE mengukur rata – rata dari kuadrat kesalahan. MSE lebih memberatkan kesalahan yang lebih besar, yang berguna dalam beberapa konteks karena kesalahan besar mungkin lebih merugikan daripada kesalahan kecil[29].

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (14)$$

Pada rumus (14) y_i adalah nilai sebenarnya, \hat{y}_i adalah nilai prediksi, dan n adalah jumlah total observasi.

2.5.8. RMSE

RMSE adalah akar kuadrat dari MSE dan memberikan penilaian yang relatif terhadap besar kesalahan prediksi, serupa dengan standar deviasi untuk data prediksi[30].

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (15)$$

Pada rumus (15) y_i adalah nilai sebenarnya, \hat{y}_i adalah nilai prediksi, dan n adalah jumlah total observasi.

2.5.9. R²

R², atau koefisien determinasi, mengukur seberapa baik prediksi masa depan kemungkinan akan, relatif terhadap nilai rata-rata dari data yang sebenarnya. R² adalah proporsi varians dalam variabel dependen yang dapat diprediksi dari variabel independen[31].

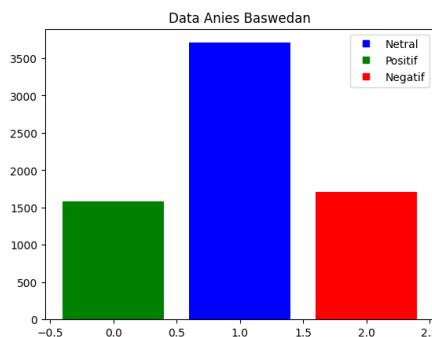
$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

Pada rumus (16) y_i adalah nilai sebenarnya, \hat{y}_i adalah nilai prediksi, \bar{y} adalah nilai rata-rata dari \hat{y}_i , dan n adalah jumlah total observasi.

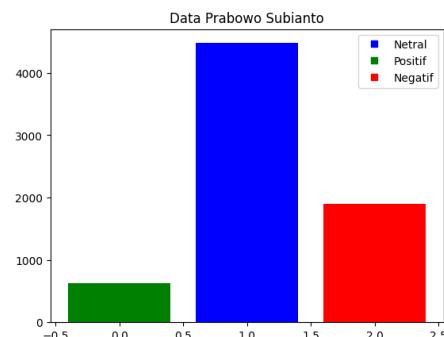
3. HASIL DAN PEMBAHASAN

Pada penelitian ini, dataset yang digunakan adalah dataset kandidat presiden 2024, Anies Baswedan, Prabowo Subianto dan Ganjar Pranowo yang didapat dari penelitian [32]. Dataset ini digunakan sebagai bahan untuk melakukan *training machine learning*. Untuk setiap data kandidat terdiri dari 9 variabel dan 10000 data. Ketiga dataset tersebut terdapat *missing value* pada variabel *tweet*, kemudian dilakukan *handling missing value* dengan mengisi nilai string kosong. Selanjutnya, dilakukan *encoding data* pada label variabel Sentiment yang didapat dari hasil perhitungan oleh BERT yang merupakan data kategorikal. Setelah itu, dilakukan normalisasi data menggunakan metode *Standard Scaler* untuk menyama ratakan rentang nilai variabel intensitas Positif, Netral dan Negatif.

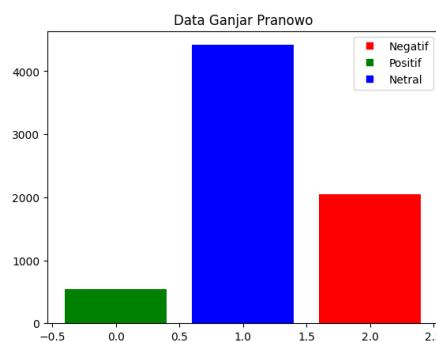
3.1. Over-sampling menggunakan SMOTE



Gambar 2. Perbandingan Label Dataset Anies Baswedan Sebelum SMOTE



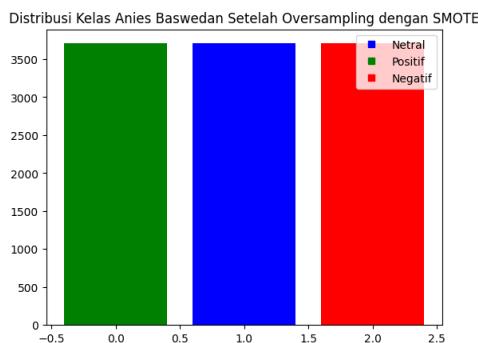
Gambar 3. Perbandingan Label Dataset Prabowo Subianto Sebelum SMOTE



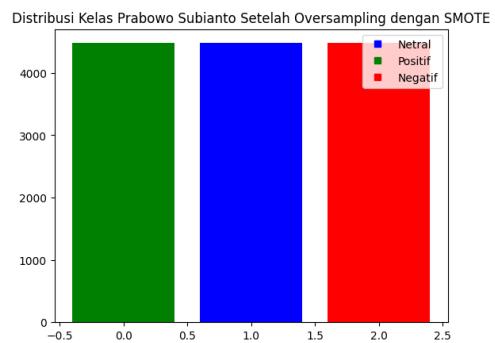
Gambar 4. Perbandingan Label Dataset Ganjar Pranowo Sebelum SMOTE

Pada gambar 2, gambar 3 dan gambar 4 dapat dilihat bahwa kondisi ketiga dataset mengalami *imbalanced class*. Perbedaan signifikan antar *class* dapat dilihat pada gambar 4, sehingga perbedaan distribusi antar *class* dapat menyebabkan *training model* yang kurang maksimal. Kelas minoritas yang memiliki sampel lebih

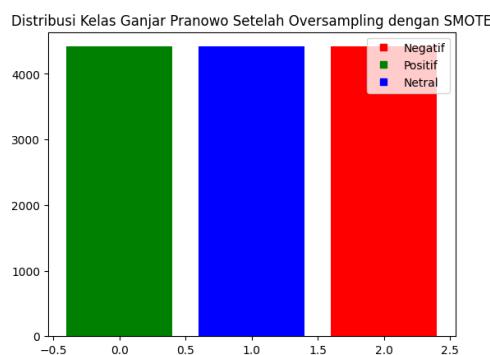
sedikit akan dikalikan dengan data sintetis yang dihasilkan oleh SMOTE agar menghasilkan distribusi data yang lebih merata saat menggunakan SMOTE.



Gambar 5 Perbandingan Label Dataset Anies Baswedan Setelah SMOTE



Gambar 6 Perbandingan Label Dataset Prabowo Subianto Setelah SMOTE



Gambar 7 Perbandingan Label Dataset Ganjar Pranowo Setelah SMOTE

Sebelum melakukan *over-sampling*, dataset dibagi menjadi 2 yaitu data *training*, sebagai contoh data yang berjumlah 70% dari total data dan data *testing* yang berjumlah 30% dari total data. Pembagian data ini berlaku pada ketiga dataset yang digunakan. Untuk menghasilkan model yang akurat, data *training* akan dilakukan proses *over-sampling*. Setelah melewati proses tersebut menggunakan SMOTE, label pada dataset Anies Baswedan, Prabowo Subianto dan Ganjar Pranowo memiliki jumlah yang sama, hal ini terlihat pada gambar 5, gambar 6 dan gambar 7. Dapat disimpulkan bahwa *over-sampling* SMOTE berhasil digunakan untuk meningkatkan jumlah dataset untuk mencapai jumlah yang seimbang.

3.1.1. Performa Model Sebelum dan Sesudah SMOTE

Untuk mengevaluasi dampak penerapan SMOTE, dilakukan perbandingan hasil pemodelan menggunakan dataset sebelum dan sesudah dilakukan *over-sampling*. Tabel 1 berikut menampilkan ringkasan performa model SVM kernel linear dengan rasio data 70:30 sebagai contoh representatif.

Tabel 1. Perbandingan Performa Model Sebelum dan Sesudah SMOTE (SVM Linear, rasio 70:30)

Kandidat	Kondisi	Accuracy	Precision	Recall	F1-Score	AUC
Anies Baswedan	Sebelum	0.85	0.87	0.89	0.88	0.91
	SMOTE					
	Sesudah	0.99	0.99	0.99	0.99	0.99
	SMOTE					
Prabowo Subianto	Sebelum	0.91	0.87	0.76	0.94	0.94
	SMOTE					
	Sesudah	0.99	0.99	0.99	0.99	0.99
	SMOTE					
Ganjar Pranowo	Sebelum	0.89	0.83	0.64	0.72	0.93
	SMOTE					
	Sesudah	0.99	0.99	0.99	0.99	0.99
	SMOTE					

3.2. Pemodelan

Setelah melewati proses *cleaning text* dan *handling imbalanced class*, dilakukan pemodelan algoritma SVM dengan empat kernel dan tiga jenis pembagian rasio: 70:30, 80:20 dan 90:10 untuk mengevaluasi model dalam berbagai skenario ukuran data *training* dan *testing* untuk prediksi klasifikasi sentimen. Setelah itu, dilakukan juga pemodelan regresi menggunakan *Ridge Regression* untuk memprediksi konsistensi nilai skor intensitas terhadap kategori sentimen nya. Dari eksperimen tersebut, didapat evaluasi pada tabel 2 untuk hasil evaluasi model klasifikasi dan tabel 3 untuk hasil evaluasi model regresi.

Tabel 2. Rekap Evaluasi Model Prediksi Klasifikasi Sentimen

SVM Kernels	Kandidat	Rasio	Accuracy	Precision	Recall	F1-Score	AUC
SVM - Linear	Anies Baswedan	70:30	0.99	0.99	0.99	0.99	0.99
		80:20	0.92	0.95	0.83	0.89	0.94
		90:10	0.93	0.97	0.83	0.90	0.95
	Prabowo Subianto	70:30	0.99	0.99	0.99	0.99	0.99
		80:20	0.92	0.95	0.83	0.89	0.94
		90:10	0.93	0.97	0.83	0.90	0.95
	Ganjar Pranowo	70:30	0.99	0.99	0.99	0.99	0.99
		80:20	0.92	0.98	0.86	0.92	0.94
		90:10	0.84	0.90	0.75	0.82	0.95
SVM - Polynomial	Anies Baswedan	70:30	0.99	0.99	1.00	1.00	0.99
		80:20	0.84	0.92	0.61	0.73	0.96
		90:10	0.85	0.90	0.62	0.73	0.96
	Prabowo Subianto	70:30	0.98	0.98	0.98	0.98	0.99
		80:20	0.84	0.92	0.61	0.73	0.96
		90:10	0.85	0.90	0.62	0.73	0.96
	Ganjar Pranowo	70:30	0.98	0.98	0.98	0.98	0.99
		80:20	0.84	0.92	0.61	0.73	0.93
		90:10	0.93	0.98	0.88	0.93	0.93
SVM - RBF	Anies Baswedan	70:30	0.99	0.99	0.99	1.00	0.97
		80:20	0.88	0.98	0.70	0.81	0.98
		90:10	0.90	0.97	0.74	0.84	0.94
	Prabowo Subianto	70:30	0.99	0.99	0.99	1.00	0.97
		80:20	0.88	0.98	0.70	0.81	0.98
		90:10	0.90	0.97	0.74	0.84	0.94
	Ganjar Pranowo	70:30	0.99	0.99	0.99	1.00	0.97

		80:20	0.94	0.98	0.90	0.94	0.98
		90:10	0.91	0.98	0.85	0.91	0.94
SVM Sigmoid	- Anies Baswedan	70:30	0.87	0.99	0.97	0.95	0.95
		80:20	0.90	0.87	0.84	0.86	0.93
		90:10	0.92	0.91	0.85	0.88	0.91
	Prabowo Subianto	70:30	0.98	0.98	0.98	0.98	0.99
		80:20	0.90	0.87	0.84	0.86	0.93
		90:10	0.92	0.91	0.85	0.88	0.91
	Ganjar Pranowo	70:30	0.89	0.93	0.87	0.90	0.95
		80:20	0.90	0.87	0.84	0.86	0.93
		90:10	0.88	0.90	0.85	0.88	0.92

Tabel 3. Rekap Evaluasi Model Prediksi Intensitas Sentimen

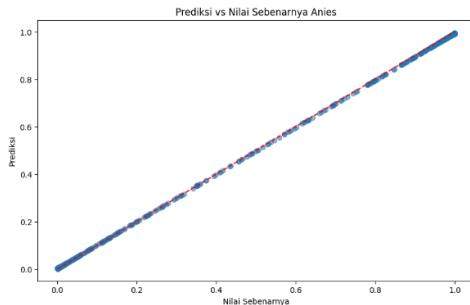
Model	Kandidat	Rasio	MAE	MSE	RMSE	MAPE	R ²
Ridge Regression	Anies Baswedan	70:30	0.006	6.401	0.008	26.778	0.99
		80:20	0.005	5.021	0.007	23.192	0.99
		90:10	0.005	3.812	0.006	21.263	0.99
	Prabowo Subianto	70:30	0.003	1.388	0.003	8.822	0.99
		80:20	0.002	1.060	0.003	7.831	0.99
		90:10	0.002	8.417	0.002	6.745	0.99
	Ganjar Pranowo	70:30	0.003	1.403	0.003	8.636	0.99
		80:20	0.002	1.073	0.003	7.666	0.99
		90:10	0.002	8.635	0.002	6.055	0.99

Selain pembagian data *train-test*, dilakukan juga validasi silang *10-fold cross-validation*. Hasilnya menunjukkan bahwa akurasi model berada pada rentang 99.42% hingga 100%, dengan rata-rata sebesar 99.77% dan standar deviasi 0.25% yang artinya performa model konsisten dan stabil pada berbagai subset data, sehingga mengurangi potensi *overfitting*.

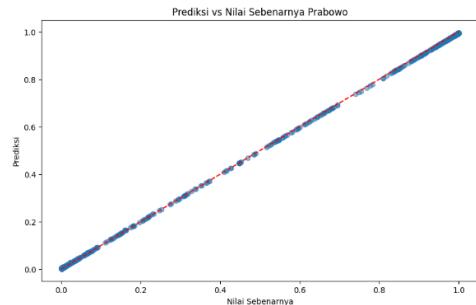
Kemudian, berdasarkan hasil evaluasi metrik pada tabel, pemodelan prediksi klasifikasi sentimen dan prediksi intensitas sentimen menggunakan pendekatan *hybrid* dari BERT dan SVM menunjukkan hasil yang sangat signifikan. Pada model SVM dengan kernel Linear, kandidat Anies Baswedan dan Prabowo Subianto dengan rasio data 70:30 menunjukkan performa terbaik dengan nilai akurasi, presisi, recall, F1-Score, dan AUC yang hampir sempurna. Untuk kernel Polynomial, performa terbaik juga dicapai pada rasio data 70:30 dengan nilai F1-Score dan AUC sangat tinggi, meskipun sedikit menurun pada rasio data yang lebih tinggi. Kernel RBF menunjukkan hasil yang sangat baik untuk semua kandidat dengan metrik evaluasi mendekati nilai maksimum, terutama pada rasio data 70:30. Namun, kernel Sigmoid menunjukkan penurunan signifikan pada metrik recall dan F1-Score pada rasio data 80:20 dan 90:10. Selain itu, model *Ridge Regression* menunjukkan kinerja yang sangat baik dalam prediksi intensitas sentimen dengan nilai *R-squared* hampir sempurna dan kesalahan prediksi yang sangat kecil untuk semua kandidat dan rasio data. Sehingga, Model *hybrid* ini tidak hanya dapat mengklasifikasikan sentimen dengan sangat akurat, tetapi juga dapat mengukur intensitas sentimen secara kuantitatif. Dalam hal analisis opini publik, metode ini memberikan informasi yang lebih kaya dan mendalam daripada metode klasifikasi konvensional.

Kemudian pada Gambar 8, Gambar 9, dan Gambar 10 ditunjukkan hasil plot antara nilai prediksi dan nilai sebenarnya dari model *Ridge Regression* yang diterapkan pada data sentimen untuk tiga kandidat: Anies Baswedan, Prabowo

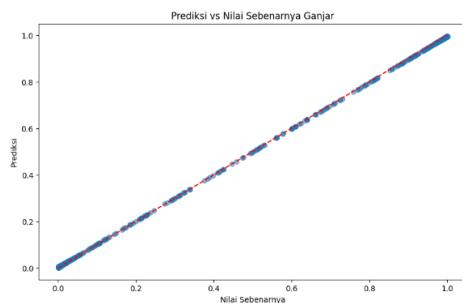
Subianto, dan Ganjar Pranowo. Sumbu horizontal (x) merepresentasikan nilai sebenarnya, sementara sumbu vertikal (y) menunjukkan nilai prediksi. Titik – titik biru pada plot ini mewakili pasangan data antara nilai prediksi dan nilai sebenarnya. Dari ketiga gambar tersebut dapat disimpulkan bahwa model *Ridge Regression* yang diterapkan telah berhasil memberikan prediksi yang hampir identik dengan nilai sebenarnya. Karena itu, model ini terbukti efektif dan akurat dalam memprediksi intensitas sentimen publik terhadap ketiga kandidat.



Gambar 8. Hasil Prediksi dan Aktual Data Anies Baswedan

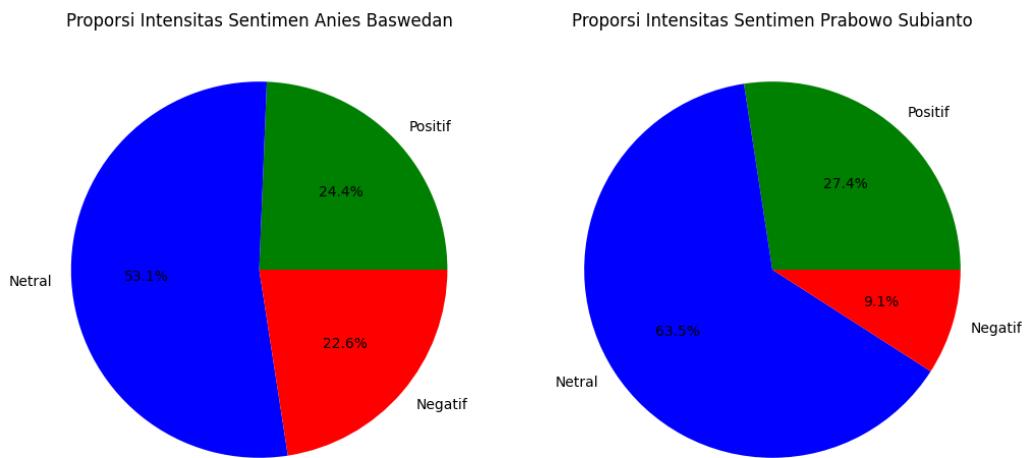


Gambar 9. Hasil Prediksi dan Aktual Data Prabowo Subianto



Gambar 10. Hasil Prediksi dan Aktual Data Ganjar Pranowo

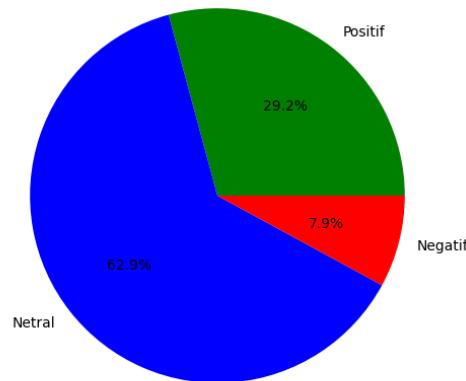
Selanjutnya, hasil dari prediksi intensitas untuk Anies Baswedan, Prabowo Subianto dan Ganjar Pranowo dapat dilihat pada gambar 11, gambar 12 dan gambar 13.



Gambar 11. Proporsi Intensitas Sentimen Anies Baswedan

Gambar 12. Proporsi Intensitas Prabowo Subianto

Proporsi Intensitas Sentimen Ganjar Pranowo



Gambar 13. Proporsi Intensitas Ganjar Pranowo

Pada gambar 11, proporsi intensitas sentimen Anies Baswedan terdiri dari Positif, Netral, dan Negatif. Dominasi sentimen Netral sebesar 53.1% menandakan bahwa sebagian besar tweet tidak mengandung emosi yang kuat atau cenderung lebih objektif. Meskipun intensitas Positif dan Negatif lebih rendah, dengan 24.4% dan 22.6% masing-masing, keduanya masih mencerminkan keberadaan respon emosional yang signifikan di antara pengguna. Proporsi yang signifikan dari sentimen negatif mengindikasikan bahwa ada sejumlah kritik atau ketidaksetujuan yang cukup besar terhadap Anies, yang penting untuk dipertimbangkan dalam analisis sentimen politik.

Kemudian pada gambar 12 analisis sentimen Prabowo Subianto menunjukkan bahwa sentimen Netral masih mendominasi dengan 63.5%. Hal ini menunjukkan bahwa diskusi tentang Prabowo cenderung objektif atau berfokus pada isu daripada emosi. Sentimen Positif dan Negatif yang tercatat adalah 27.4% dan 9.1%, menggambarkan bahwa meskipun ada dukungan, tingkat penolakan terhadap

Prabowo relatif rendah, yang menunjukkan bahwa opini negatif terhadapnya tidak seintensif terhadap Anies.

Untuk gambar 13, yang menampilkan proporsi intensitas sentimen Ganjar Pranowo, sentimen Netral juga mendominasi dengan persentase 62.9%. Namun, Ganjar memiliki persentase sentimen Positif yang cukup tinggi yaitu 29.2%, menunjukkan adanya kepuasan yang lebih besar dari kalangan pengguna media sosial Twitter terhadap kandidat Ganjar Pranowo. Persentase Sentimen Negatif yang tercatat hanya 7.9%, yang paling rendah di antara ketiga kandidat, menunjukkan bahwa Ganjar menghadapi kritik yang lebih sedikit, sehingga mencerminkan citra publik yang lebih positif dibandingkan dengan dua kandidat lainnya selama periode analisis.

Analisis kualitatif lebih lanjut menunjukkan bahwa pola distribusi ini memiliki implikasi strategis dalam konteks pemilu. Anies menghadapi tantangan berupa proporsi sentimen negatif yang tinggi, sehingga strategi kampanye perlu difokuskan pada klarifikasi isu dan perbaikan citra publik. Prabowo memiliki dominasi sentimen netral yang luas, yang menandakan ruang besar untuk dikonversi menjadi dukungan aktif melalui pendekatan komunikasi yang lebih emosional dan personal. Sementara itu, Ganjar memiliki keunggulan berupa tingginya sentimen positif dan rendahnya sentimen negatif, yang dapat menjadi modal politik signifikan. Namun, konsistensi dukungan harus dijaga agar sentimen positif tidak bergeser menjadi netral atau negatif di kemudian hari.

4. KESIMPULAN

Pada penelitian sebelumnya yang disajikan dalam Tabel 3, berbagai metode telah digunakan untuk menganalisis sentimen dari tweet yang berkaitan dengan pemilihan umum di berbagai negara. Penelitian [32] menggunakan model SVM untuk tweet tentang pemilihan presiden di Indonesia, berhasil mencapai akurasi 87%. Penelitian [33] menerapkan Multinomial Naïve Bayes untuk pemilihan presiden Filipina dengan akurasi 84%, sementara penelitian [34] menggunakan BERT untuk konteks yang sama dan mendapatkan akurasi yang lebih tinggi, yaitu 93%. Ini menunjukkan keefektifan BERT dalam memproses teks kompleks. Penelitian [35] menggunakan Naïve Bayes untuk analisis tweet pada pemilihan kepala daerah di Indonesia, dengan akurasi 92%. Penelitian [16] menggunakan KNN untuk mengklasifikasikan tweet dengan akurasi 81% dan memprediksi hasil pemilihan presiden AS menggunakan KNN Regressor dengan RMSE 0.1526. Dua penelitian tambahan, [17] dan [18], menggunakan *Logistic Regression* untuk menganalisis tweet terkait pemilihan presiden Amerika dan maskapai penerbangan AS.

Penelitian ini menunjukkan bahwa model *hybrid* yang dikembangkan, dengan mengombinasikan klasifikasi menggunakan SVM dan pengukuran intensitas menggunakan *Ridge Regression*, mampu mengungguli metode sebelumnya dalam hal akurasi dan kedalaman analisis. Dibandingkan metode lain seperti SVM konvensional dengan akurasi 87% [32] dan BERT standar yang hanya mencapai akurasi 93% [34], model ini mencapai akurasi klasifikasi sebesar 99%. Selain itu, penggunaan regresi memungkinkan pengukuran kekuatan emosional dari sentimen, suatu hal yang tidak tersedia dalam model klasifikasi biasa.

Tabel 4. Perbandingan Penelitian Sebelumnya

Ref	Model	Dataset	Intensitas	Ratio	SMOTE	Regresi	Akurasi	MAE	MSE	RMSE	MAPE	R ²
[32] (2024)	SVM	Tweet kandidat presiden Indonesia	✗	✓	✗	✗	87	-	-	-	-	-
[33] (2022)	Multinomial Naïve Bayes	Tweet mengenai Presiden Filipina	✗	✓	✗	✗	84	-	-	-	-	-
[34] (2022)	BERT	Tweet mengenai Presiden Indonesia	✗	✗	✗	✗	93	-	-	-	-	-
[35] (2021)	Naïve Bayes	Tweet kandidat kepala daerah	✗	✓	✗	✗	92	-	-	-	-	-
[16] (2021)	KNN Regressor	Tweet kandidat presiden Amerika	✗	✗	✗	✓	81	-	-	0.1526	-	-
[17] (2020)	Logistic Regression	Tweet kandidat presiden Spanyol	✓	✗	✗	✓	-	-	-	-	-	-
[18] (2019)	Logistic Regression	Tweet mengenai US Airlines	✓	✗	✗	✓	78	-	-	-	-	-
PM	Ridge Regression	Tweet kandidat presiden Indonesia	✓	✓	✓	✓	99	0.002	8.635	0.002	6.055	0.99

Proposed Method (PM) pada penelitian ini adalah menggunakan model *hybrid* untuk menganalisis sentimen dan intensitasnya dalam konteks pemilihan umum di Indonesia yang didapat dari hasil perhitungan oleh BERT, mencapai akurasi yang sangat tinggi sebesar 99% untuk prediksi klasifikasi sentimen dengan SVM dan SMOTE serta menunjukkan efektivitas dalam mengukur intensitas sentimen dengan MAE dan MSE yang sangat rendah serta R^2 yang sangat tinggi. Hasil dari pemodelan regresi pun untuk data aktual dan prediksinya dapat dilihat pada gambar 8, gambar 9 dan gambar 10. Kemudian, hasil intensitas yang dijelaskan pada gambar 11 untuk kandidat Anies Baswedan mayoritas sentimen adalah netral sebesar 53.1%. Selanjutnya, pada gambar 12 untuk kandidat Prabowo Subianto netral sebesar 63.5% dan gambar 13 untuk kandidat Ganjar Pranowo dengan 62.9%.

Meskipun performa model menunjukkan hasil yang hampir sempurna dengan akurasi dan nilai evaluasi lainnya yang sangat tinggi, penelitian ini tetap memiliki beberapa keterbatasan. Data yang digunakan terbatas pada Twitter dan periode waktu tertentu, sehingga masih terdapat potensi bias dalam merepresentasikan opini publik secara menyeluruh. Selain itu, model belum sepenuhnya mampu menangkap konteks bahasa yang lebih kompleks, seperti ironi, sarkasme, maupun variasi bahasa informal yang sering muncul di media sosial. Dalam implementasi praktis, model ini memiliki potensi besar untuk digunakan sebagai alat pemantauan opini publik secara real-time maupun untuk topik politik lain di luar pemilu. Namun, agar lebih adaptif, penelitian lanjutan perlu mengintegrasikan data dari

berbagai platform media sosial, memperbarui model secara periodik, serta mengembangkan pendekatan yang lebih sensitif terhadap nuansa bahasa untuk meningkatkan keandalan hasil analisis.

REFERENSI

- [1] R. Zaiter, N. Sabbagh, and M. Koabaz, “The Impact of Social Media on Political Efficacy and Real-Life Netizens Political Participation (Lebanon-Case Study),” *International Journal of Professional Business Review*, vol. 8, no. 5, p. e02153, May 2023, doi: 10.26668/businessreview/2023.v8i5.2153.
- [2] H. H. Guedea-Noriega and F. García-Sánchez, “Integroly: Automatic Knowledge Graph Population from Social Big Data in the Political Marketing Domain,” *Applied Sciences (Switzerland)*, vol. 12, no. 16, Aug. 2022, doi: 10.3390/app12168116.
- [3] S. Berg, T. König, and A. K. Koster, “Political opinion formation as epistemic practice: the hashtag assemblage of #metwo,” *Media Commun*, vol. 8, no. 4, pp. 84–95, 2020, doi: 10.17645/mac.v8i4.3164.
- [4] W. van Atteveldt, M. A. C. G. van der Velden, and M. Boukes, “The Validity of Sentiment Analysis: Comparing Manual Annotation, Crowd-Coding, Dictionary Approaches, and Machine Learning Algorithms,” *Commun Methods Meas*, vol. 15, no. 2, pp. 121–140, 2021, doi: 10.1080/19312458.2020.1869198.
- [5] A. Yenkikar and C. N. Babu, “SentiMLBench: Benchmark Evaluation of Machine Learning Algorithms for Sentiment Analysis,” *Indonesian Journal of Electrical Engineering and Informatics*, vol. 11, no. 1, pp. 318–336, Mar. 2023, doi: 10.52549/ijeei.v11i1.4381.
- [6] A. A. Firdaus, A. Yudhana, I. Riadi, and Mahsun, “Indonesian presidential election sentiment: Dataset of response public before 2024,” *Data Brief*, vol. 52, Feb. 2024, doi: 10.1016/j.dib.2023.109993.
- [7] N. K. Nissa and E. Yulianti, “Multi-label text classification of Indonesian customer reviews using bidirectional encoder representations from transformers language model,” *International Journal of Electrical and Computer Engineering*, vol. 13, no. 5, pp. 5641–5652, Oct. 2023, doi: 10.11591/ijece.v13i5.pp5641-5652.
- [8] H. Murfi, F. L. Siagian, and Y. Satria, “Topic features for machine learning-based sentiment analysis in Indonesian tweets,” *International Journal of Intelligent Computing and Cybernetics*, vol. 12, no. 1, pp. 70–81, Feb. 2019, doi: 10.1108/IJICC-04-2018-0057.
- [9] M. N. Habibi and Sunjana, “Analysis of Indonesia Politics Polarization before 2019 President Election Using Sentiment Analysis and Social Network Analysis,” *International Journal of Modern Education and Computer Science*, vol. 11, no. 11, pp. 22–30, Nov. 2019, doi: 10.5815/ijmecs.2019.11.04.
- [10] M. C. Galgoczy, A. Phatak, D. Vinson, V. K. Mago, and P. J. Giabbanelli, “(Re) shaping online narratives: when bots promote the message of President Trump during his first impeachment,” *PeerJ Comput Sci*, vol. 8, p. e947, 2022.

- [11] S. E. Bestvater and B. L. Monroe, "Sentiment is not stance: Target-aware opinion classification for political text analysis," *Political Analysis*, vol. 31, no. 2, pp. 235–256, 2023.
- [12] C. Chang and X. Wang, "Research on Dynamic Political Sentiment Polarity analysis of specific group Twitter based on Deep learning method," in *Journal of Physics: Conference Series*, 2020, p. 12108.
- [13] O. Olabanjo *et al.*, "From Twitter to Aso-Rock: A sentiment analysis framework for understanding Nigeria 2023 presidential election," *Heliyon*, vol. 9, no. 5, 2023.
- [14] A. AlDayel and W. Magdy, "Stance detection on social media: State of the art and trends," *Inf Process Manag*, vol. 58, no. 4, p. 102597, 2021.
- [15] H. N. Chaudhry *et al.*, "Sentiment analysis of before and after elections: Twitter data of US election 2020," *Electronics (Basel)*, vol. 10, no. 17, p. 2082, 2021.
- [16] R. Liu, X. Yao, C. Guo, and X. Wei, "Can we forecast presidential election using twitter data? an integrative modelling approach," *Ann GIS*, vol. 27, no. 1, pp. 43–56, 2021.
- [17] D. Grimaldi, J. D. Cely, and H. Arboleda, "Inferring the votes in a new political landscape: The case of the 2019 Spanish Presidential elections," *J Big Data*, vol. 7, no. 1, p. 58, 2020.
- [18] F. Rustam, I. Ashraf, A. Mehmood, S. Ullah, and G. S. Choi, "Tweets classification on the base of sentiments for US airline companies," *Entropy*, vol. 21, no. 11, p. 1078, 2019.
- [19] A. S. Talaat, "Sentiment analysis classification system using hybrid BERT models," *J Big Data*, vol. 10, no. 1, p. 110, 2023.
- [20] J. Zhao and Y. Sheng, "Uncertain support vector machine based on uncertain set theory," *Journal of Intelligent & Fuzzy Systems*, no. Preprint, pp. 1–12, 2023.
- [21] M. Khatun and S. Siddiqui, "Estimating Conditional Event Probabilities with Mixed Regressors: a Weighted Nearest Neighbour Approach.," *Statistika: Statistics & Economy Journal*, vol. 103, no. 2, 2023.
- [22] L. Yuningsih, G. A. Pradipta, D. Hermawan, P. D. W. Ayu, D. P. Hostiadi, and R. R. Huizen, "IRS-BAG-Integrated Radius-SMOTE Algorithm with Bagging Ensemble Learning Model for Imbalanced Data Set Classification," *Emerging Science Journal*, vol. 7, no. 5, pp. 1501–1516, Oct. 2023, doi: 10.28991/ESJ-2023-07-05-04.
- [23] S. Esfahanian and E. Lee, "A novel packaging evaluation method using sentiment analysis of customer reviews," *Packaging Technology and Science*, vol. 35, no. 12, pp. 903–911, Dec. 2022, doi: 10.1002/pts.2686.
- [24] K. Takahashi, K. Yamamoto, A. Kuchiba, and T. Koyama, "Confidence interval for micro-averaged F 1 and macro-averaged F 1 scores," *Applied Intelligence*, vol. 52, no. 5, pp. 4961–4972, 2022.
- [25] A. Fleerackers, L. Nehring, L. A. Maggio, A. Enkhbayar, L. Moorhead, and J. P. Alperin, "Identifying science in the news: An assessment of the precision and recall of Altmetric. com news mention data," *Scientometrics*, vol. 127, no. 11, pp. 6109–6123, 2022.
- [26] M. Sitarz, "Extending F1 metric, probabilistic approach," *arXiv preprint arXiv:2210.11997*, 2022.

- [27] S. Sumukha and others, “Analysis of Traffic Accident Features and Crash Severity Prediction,” *International Journal of Cognitive Informatics and Natural Intelligence (IJCINI)*, vol. 15, no. 4, pp. 1–18, 2021.
- [28] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput Sci*, vol. 7, p. e623, 2021.
- [29] T. O. Hodson, “Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not,” *Geoscientific Model Development Discussions*, vol. 2022, pp. 1–10, 2022.
- [30] I. C. Kaplan *et al.*, “Management strategy evaluation: allowing the light on the hill to illuminate more than one species,” *Front Mar Sci*, vol. 8, p. 624355, 2021.
- [31] A. R. Srinivasan *et al.*, “Beyond RMSE: Do machine-learned models of road user interaction produce human-like behavior?,” *IEEE Transactions on Intelligent Transportation Systems*, 2023.
- [32] A. A. Firdaus, A. Yudhana, I. Riadi, and Mahsun, “Indonesian presidential election sentiment: Dataset of response public before 2024,” *Data Brief*, vol. 52, Feb. 2024, doi: 10.1016/j.dib.2023.109993.
- [33] J. J. E. Macrohon, C. N. Villavicencio, X. A. Inbaraj, and J.-H. Jeng, “A semi-supervised approach to sentiment analysis of tweets during the 2022 Philippine presidential election,” *Information*, vol. 13, no. 10, p. 484, 2022.
- [34] F. Said and L. Parningotan Manik, “Aspect-Based Sentiment Analysis on Indonesian Presidential Election Using Deep Learning,” *Paradigma*, vol. 24, no. 2, pp. 160–167, 2022, doi: 10.31294/p.v24i2.1415.
- [35] A. Muzaki and A. Witanti, “SENTIMENT ANALYSIS OF THE COMMUNITY IN THE TWITTER TO THE 2020 ELECTION IN PANDEMIC COVID-19 BY METHOD NAIVE BAYES CLASSIFIER,” *Jurnal Teknik Informatika (Jutif)*, vol. 2, no. 2, pp. 101–107, Mar. 2021, doi: 10.20884/1.jutif.2021.2.2.51.