Department of Digital Business
**Journal of Artificial Intelligence and Digital Business (RIGGS)**
Homepage: https://journal.ilmudata.co.id/index.php/RIGGS
Vol. 5 No. 2 (2026) pp: 9914-9923
P-ISSN: 2963-9298, e-ISSN: 2963-914X

# Analisis Sentimen terhadap Perencanaan Pemilu Elektronik di Indonesia Menggunakan Pendekatan Soft Voting Ensemble

I Putu Dennis Prana Arta[1], Putu Hendra Suputra[2], I Gusti Ayu Agung Diatri Indradewi[3]
[1]Sistem Informasi, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha
[2]Ilmu Komputer, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha
[3]Sistem Informasi, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha
[1]dennis@student.undiksha.ac.id, [2]hendra.suputra@undiksha.ac.id, [3]indradewi@undiksha.ac.id

***Abstrak***

*Pemilu elektronik merupakan salah satu inovasi yang berpotensi meningkatkan efisiensi, transparansi, dan akurasi dalam penyelenggaraan pemilihan umum. Namun, implementasinya masih menimbulkan beragam tanggapan dari masyarakat yang banyak disampaikan melalui media sosial. Penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap implementasi pemilu elektronik di Indonesia menggunakan metode Soft Voting Ensemble. Penelitian menerapkan kerangka kerja CRISP-DM dengan memanfaatkan data yang diperoleh dari platform X dan TikTok. Dari 9.715 data yang berhasil dikumpulkan, diperoleh 3.979 data relevan setelah proses seleksi, yang kemudian dilabeli secara manual oleh tiga ahli bahasa Indonesia menjadi 1.446 sentimen positif dan 2.533 sentimen negatif. Tahapan penelitian meliputi preprocessing, pembobotan TF-IDF, penanganan ketidakseimbangan data menggunakan Borderline-SMOTE, klasifikasi menggunakan Logistic Regression, Random Forest, dan Soft Voting Ensemble, serta evaluasi menggunakan confusion matrix dan 5-Fold Cross Validation. Hasil penelitian menunjukkan bahwa model Soft Voting Ensemble dengan optimasi awal dan Borderline-SMOTE menghasilkan performa terbaik dengan akurasi sebesar 80,78%. Selain itu, analisis topik menggunakan Latent Dirichlet Allocation (LDA) berhasil mengidentifikasi topik-topik dominan yang memengaruhi sentimen positif dan negatif masyarakat terhadap pemilu elektronik. Hasil penelitian juga diimplementasikan dalam bentuk dashboard interaktif untuk mendukung visualisasi dan pemanfaatan informasi oleh pemangku kepentingan. Temuan penelitian menunjukkan bahwa pendekatan Soft Voting Ensemble efektif dalam menganalisis sentimen publik terhadap implementasi pemilu elektronik di Indonesia.*

***Kata Kunci**: Analisis Sentimen, Pemilu Elektronik, Soft Voting Ensemble, Topic Modeling, Latent Dirichlet Allocation, Visualisasi Dashboard*

## 1. Latar Belakang

Pemilu elektronik merupakan salah satu bentuk transformasi digital dalam penyelenggaraan pemilihan umum yang memanfaatkan teknologi informasi untuk meningkatkan efisiensi, transparansi, dan akurasi proses pemungutan suara. Seiring perkembangan teknologi, pemilu elektronik mulai dipertimbangkan sebagai alternatif untuk mengatasi berbagai permasalahan teknis dan administratif dalam penyelenggaraan pemilu konvensional. Di Indonesia, wacana penerapan pemilu elektronik terus berkembang sebagai upaya modernisasi sistem demokrasi. Namun, implementasi sistem tersebut masih menghadapi berbagai tantangan, seperti kesiapan infrastruktur, regulasi, keamanan sistem, serta tingkat literasi digital masyarakat yang berpotensi memengaruhi kepercayaan publik terhadap hasil pemilu yang diselenggarakan secara elektronik [1], [2]. Selain itu, penelitian sebelumnya menunjukkan bahwa pemilu elektronik masih memunculkan beragam tanggapan dari masyarakat, terutama terkait aspek keamanan data, transparansi proses, dan keandalan sistem dalam menjamin integritas hasil pemilu [3].

Perkembangan media sosial telah memberikan ruang bagi masyarakat untuk menyampaikan opini terhadap berbagai isu publik secara terbuka dan real-time. Platform X dan TikTok menjadi media yang banyak digunakan untuk menyampaikan dukungan, kritik, maupun kekhawatiran terhadap rencana penerapan pemilu elektronik. Karakteristik kedua platform tersebut menghasilkan data opini dalam jumlah besar yang dapat dimanfaatkan untuk memahami persepsi masyarakat secara aktual [4], [5]. Untuk mengolah data tersebut secara efektif, analisis sentimen menjadi salah satu pendekatan yang banyak digunakan dalam bidang Natural Language Processing (NLP). Analisis sentimen memungkinkan identifikasi dan klasifikasi opini masyarakat ke dalam kategori sentimen positif maupun negatif sehingga dapat memberikan gambaran mengenai tingkat penerimaan publik terhadap suatu

kebijakan [6]. Selain itu, analisis sentimen telah banyak dimanfaatkan untuk mengevaluasi persepsi masyarakat terhadap berbagai isu sosial dan kebijakan publik melalui data media sosial [7].

Berbagai penelitian terdahulu menunjukkan bahwa metode machine learning memiliki performa yang baik dalam analisis sentimen. Logistic Regression terbukti mampu menghasilkan akurasi yang tinggi pada berbagai kasus klasifikasi opini publik [8]. Random Forest memiliki kemampuan yang baik dalam menangani data yang kompleks dan non-linear sehingga banyak digunakan dalam penelitian analisis sentimen berbasis media sosial [9]. Penggunaan ensemble learning melalui Soft Voting dilaporkan mampu meningkatkan performa klasifikasi dengan menggabungkan kekuatan beberapa algoritma machine learning [10]. Penelitian lain juga menunjukkan bahwa metode voting classifier dan ensemble learning secara konsisten menghasilkan performa yang lebih baik dibandingkan model individu pada berbagai domain analisis sentimen [11]. Temuan tersebut menunjukkan bahwa pendekatan ensemble memiliki potensi untuk menghasilkan model klasifikasi yang lebih akurat dan robust dibandingkan penggunaan model tunggal [12].

Meskipun penelitian analisis sentimen telah banyak dilakukan, kajian mengenai analisis sentimen masyarakat terhadap pemilu elektronik di Indonesia masih relatif terbatas dibandingkan penelitian pada domain lain seperti pendidikan, aplikasi digital, e-commerce, maupun hiburan. Sebagian besar penelitian terdahulu hanya berfokus pada proses klasifikasi sentimen tanpa mengombinasikan penanganan ketidakseimbangan data, identifikasi topik dominan, dan implementasi hasil analisis dalam suatu sistem yang terintegrasi. Berdasarkan kondisi tersebut, penelitian ini mengusulkan pendekatan Soft Voting Ensemble yang menggabungkan Logistic Regression dan Random Forest untuk menganalisis sentimen masyarakat terhadap pemilu elektronik berdasarkan data dari platform X dan TikTok. Penelitian ini juga menerapkan Borderline-SMOTE untuk menangani ketidakseimbangan data, Latent Dirichlet Allocation (LDA) untuk mengidentifikasi topik dominan pada setiap kategori sentimen, serta mengimplementasikan hasil penelitian ke dalam dashboard berbasis Streamlit. Dengan demikian, penelitian ini diharapkan dapat memberikan gambaran yang lebih komprehensif mengenai persepsi masyarakat terhadap pemilu elektronik di Indonesia serta mendukung pengambilan keputusan berbasis data bagi pemangku kebijakan.

## 2. Metode Penelitian

Penelitian ini menggunakan metodologi Cross Industry Standard Process for Data Mining (CRISP-DM) sebagai kerangka kerja dalam analisis sentimen terhadap implementasi pemilu elektronik di Indonesia [13].




Gambar 1. Tahapan Penelitian dengan CRISP-DM

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

### 2.1. *Business Understanding*

Tahap business understanding bertujuan untuk mengidentifikasi permasalahan dan menentukan tujuan penelitian. Permasalahan yang diangkat dalam penelitian ini adalah beragamnya opini masyarakat terhadap implementasi pemilu elektronik di Indonesia yang disampaikan melalui media sosial. Berdasarkan permasalahan tersebut, penelitian bertujuan untuk menganalisis sentimen masyarakat menggunakan metode Soft Voting Ensemble serta mengidentifikasi topik dominan yang memengaruhi sentimen tersebut menggunakan metode Latent Dirichlet Allocation (LDA).

### 2.2. *Data Understanding*

Tahap *data understanding* dilakukan untuk memahami karakteristik data yang digunakan dalam penelitian. Data diperoleh dari platform X dan TikTok menggunakan teknik *crawling* dan *scraping* berdasarkan kata kunci yang berkaitan dengan pemilu elektronik [14], [15]. Data yang terkumpul kemudian melalui proses seleksi untuk menghapus data yang tidak relevan, duplikat, spam, iklan, maupun konten yang tidak mengandung opini terkait topik penelitian. Selanjutnya, data yang telah diseleksi diberikan label sentimen secara manual ke dalam kategori positif dan negatif oleh tiga ahli bahasa Indonesia untuk memastikan kualitas dan konsistensi pelabelan.

### 2.3 Data Preparation

Tahap data preparation dilakukan untuk mempersiapkan data sebelum proses pemodelan. Tahapan ini meliputi cleaning, case folding, normalization, tokenization, stopword removal, dan stemming untuk menghasilkan data teks yang lebih terstruktur. Setelah proses preprocessing selesai, dataset dibagi menggunakan metode train-test split dengan rasio 80:20 untuk memperoleh data latih dan data uji [16]. Data hasil pembagian tersebut kemudian ditransformasikan ke dalam bentuk numerik menggunakan metode TF-IDF (Term Frequency-Inverse Document Frequency). Borderline-SMOTE digunakan pada data latih untuk mengatasi ketidakseimbangan distribusi kelas sehingga model dapat mempelajari karakteristik setiap kelas secara lebih optimal. Selain itu, data hasil preprocessing juga digunakan pada proses analisis topik menggunakan Count Vectorizer sebagai representasi dokumen sebelum diterapkan metode Latent Dirichlet Allocation (LDA) [17].

### 2.4 Modeling

Tahap modeling dilakukan dengan membangun model klasifikasi menggunakan algoritma Logistic Regression dan Random Forest berdasarkan fitur TF-IDF yang telah melalui proses penyeimbangan data. Kedua algoritma tersebut kemudian dikombinasikan menggunakan metode Soft Voting Ensemble yang menghasilkan keputusan klasifikasi berdasarkan probabilitas prediksi dari masing-masing model. Selain proses klasifikasi sentimen, penelitian ini juga menerapkan metode Latent Dirichlet Allocation (LDA) untuk mengidentifikasi topik-topik dominan yang muncul pada masing-masing kategori sentimen menggunakan representasi dokumen yang dihasilkan oleh Count Vectorizer [18].

### 2.5 Evaluation

Tahap evaluation dilakukan untuk mengukur performa model klasifikasi yang dibangun menggunakan confusion matrix dengan metrik accuracy, precision, recall, dan F1-score. Evaluasi dilakukan terhadap model Logistic Regression, Random Forest, dan Soft Voting Ensemble baik sebelum maupun setelah penerapan Borderline-SMOTE. Selain itu, penelitian ini menerapkan 5-Fold Cross Validation untuk menguji konsistensi performa dan kemampuan generalisasi model terhadap berbagai pembagian data sehingga diperoleh model dengan performa yang lebih optimal dan stabil.

### 2.6 Deployment

Tahap deployment dilakukan dengan mengimplementasikan hasil penelitian ke dalam dashboard interaktif berbasis Streamlit. Dashboard dikembangkan untuk menampilkan informasi terkait distribusi sentimen masyarakat terhadap pemilu elektronik, visualisasi hasil klasifikasi, performa model yang dihasilkan, serta topik dominan dari masing-masing kategori sentimen berdasarkan analisis LDA. Implementasi ini bertujuan untuk mempermudah pengguna dalam memahami hasil analisis melalui penyajian informasi yang lebih interaktif, informatif, dan mudah diakses.

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

## 3. Hasil dan Diskusi

### 3.1 Data Understanding

Tahap *data understanding* dilakukan untuk memahami karakteristik data yang digunakan dalam penelitian. Tahapan ini meliputi pengumpulan data, seleksi data, dan pelabelan sentimen. Data dikumpulkan dari platform X dan TikTok menggunakan kata kunci yang berkaitan dengan pemilu elektronik. Proses pengumpulan menghasilkan 9.715 data mentah yang terdiri dari unggahan dan komentar pengguna. Selanjutnya dilakukan proses seleksi untuk menghapus data yang tidak relevan, spam, duplikat, serta konten yang tidak mengandung opini terkait pemilu elektronik sehingga diperoleh 3.979 data yang digunakan dalam penelitian. Dataset yang telah diseleksi kemudian diberikan label sentimen secara manual oleh tiga ahli bahasa Indonesia ke dalam kategori positif dan negatif. Hasil pelabelan menunjukkan bahwa dataset didominasi oleh sentimen negatif sebanyak 2.533 data, sedangkan sentimen positif berjumlah 1.446 data. Distribusi label sentimen yang diperoleh ditunjukkan pada Gambar 2.

### 3.2 Data Preparation

Tahap data preparation bertujuan untuk mempersiapkan data sebelum digunakan pada proses klasifikasi sentimen dan analisis topik. Tahapan ini meliputi text preprocessing, transformasi data menggunakan TF-IDF dan Count Vectorizer, serta penanganan ketidakseimbangan data menggunakan Borderline-SMOTE.

a. Text Preprocessing

Tahap text preprocessing dilakukan untuk membersihkan dan menormalisasi data teks sehingga dapat diproses oleh model machine learning. Proses ini terdiri dari cleaning untuk menghapus karakter yang tidak diperlukan seperti URL, emoji, tanda baca, dan angka, case folding untuk mengubah seluruh huruf menjadi huruf kecil, normalization untuk mengubah kata tidak baku menjadi kata baku, tokenization untuk memecah kalimat menjadi token kata, stopword removal untuk menghapus kata yang tidak memiliki makna penting, serta stemming untuk mengubah kata menjadi bentuk dasarnya. Contoh hasil dari setiap tahapan preprocessing ditunjukkan pada Tabel 1.

Tabel 1. Hasil Penerapan Text Preporcessing

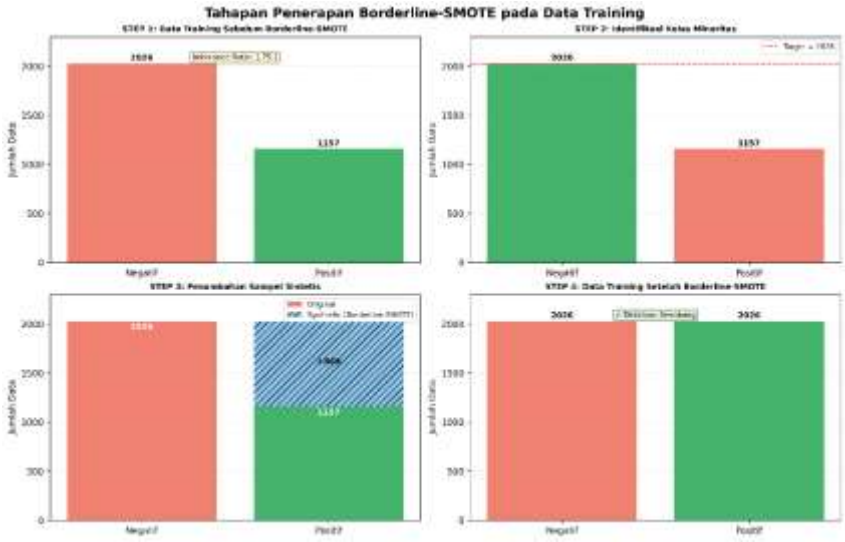
| Sebelum | Sesudah |
|---|---|
| @temposains Maaf kami tidak sependapat. E-Pemilu pun bukan berarti bisa steril dari intervensi manusia. | maaf tidak dapat epemilu steril intervensi manusia |

Setelah proses preprocessing selesai dilakukan, dataset dibagi menggunakan metode train-test split dengan rasio 80:20. Sebanyak 80% data digunakan sebagai data pelatihan (training data), sedangkan 20% sisanya digunakan sebagai data pengujian (testing data) untuk mengevaluasi performa model klasifikasi.

b. TF-IDF dan Borderline-SMOTE

Setelah proses train-test split, data teks ditransformasikan menggunakan TF-IDF (Term Frequency-Inverse Document Frequency) untuk menghasilkan representasi numerik yang digunakan sebagai fitur pada proses klasifikasi. Selanjutnya, Borderline-SMOTE diterapkan pada data pelatihan untuk mengatasi ketidakseimbangan distribusi kelas antara sentimen positif dan negatif dengan menghasilkan data sintetis pada kelas minoritas. Hasil penerapan Borderline-SMOTE menunjukkan distribusi kelas yang lebih seimbang dibandingkan sebelum proses oversampling, sebagaimana ditunjukkan pada Gambar X.

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)




Gambar 2. Tahapan Penerapan Borderline-SMOTE pada Data Training

c. CountVectorizer

Selain menggunakan TF-IDF untuk proses klasifikasi sentimen, penelitian ini juga menerapkan Count Vectorizer sebagai representasi dokumen pada proses topic modeling. Count Vectorizer digunakan untuk mengubah data teks hasil preprocessing ke dalam bentuk matriks frekuensi kata yang menunjukkan jumlah kemunculan setiap kata pada dokumen. Representasi ini digunakan sebagai masukan bagi metode Latent Dirichlet Allocation (LDA) untuk mengidentifikasi topik-topik dominan yang muncul pada sentimen positif dan negatif.

3.3 Modeling

Tahap modeling dilakukan menggunakan algoritma Logistic Regression, Random Forest, dan Soft Voting Ensemble untuk melakukan klasifikasi sentimen terhadap opini masyarakat mengenai pemilu elektronik. Pada penelitian ini, beberapa konfigurasi parameter diterapkan pada setiap model, yang terdiri atas parameter baseline, konfigurasi hasil optimasi awal, serta konfigurasi hasil hyperparameter tuning yang diperoleh melalui pengujian beberapa kandidat parameter secara manual. Rincian konfigurasi parameter yang digunakan pada masing-masing model ditunjukkan pada Tabel 2.

Tabel 2. Konfigurasi Parameter Model

| Model | Parameter | Value |
|---|---|---|
| Soft Voting Baseline | lr_C | 1,00 |
| | lr_max_iter | 2000 |
| | rf_estimators | 300 |
| | rf_depth | 25 |
| | rf_min_split | 10 |
| | rf_min_leaf | 4 |
| Soft Voting Optimasi Awal | lr_C | 4,00 |
| | lr_max_iter | 2000 |
| | rf_estimators | 400 |
| | rf_depth | 60 |
| | rf_min_split | 5 |
| | rf_min_leaf | 2 |
| Soft Voting Tuning dengan Borderline-SMOTE | lr_C | 0,75 |
| | lr_max_iter | 1000 |
| | rf_estimators | 250 |
| | rf_depth | 22 |
| | rf_min_split | 12 |
| | rf_min_leaf | 5 |
| Soft Voting Tuning tanpa Borderline-SMOTE | lr_C | 2,00 |
| | lr_max_iter | 3000 |
| | rf_estimators | 350 |
| | rf_depth | 40 |
| | rf_min_split | 6 |
| | rf_min_leaf | 2 |
| | lr_C | 1,50 |

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

| | | |
|---|---|---|
| Logistic Regression Tuning | lr_max_iter | 2000 |
| Random Forest Tuning | rf_estimators | 350 |
| | rf_depth | 40 |
| | rf_min_split | 6 |
| | rf_min_leaf | 2 |

Berdasarkan konfigurasi parameter yang telah ditentukan, penelitian ini menerapkan beberapa skenario pengujian menggunakan Logistic Regression, Random Forest, dan Soft Voting Ensemble. Setiap model diuji baik sebelum maupun setelah penerapan Borderline-SMOTE untuk mengetahui pengaruh penanganan ketidakseimbangan data terhadap performa klasifikasi. Hasil dari seluruh skenario pengujian kemudian dievaluasi menggunakan metrik accuracy, precision, recall, dan F1-score serta divalidasi menggunakan 5-Fold Cross Validation. Selain pemodelan klasifikasi, pada tahap ini juga dilakukan topic modeling menggunakan metode Latent Dirichlet Allocation (LDA) untuk mengidentifikasi topik-topik dominan yang muncul dalam opini masyarakat terkait pemilu elektronik. Analisis ini bertujuan untuk memberikan gambaran yang lebih mendalam mengenai isu-isu yang dibahas oleh pengguna di luar informasi polaritas sentimen yang dihasilkan oleh model klasifikasi.

Tabel 3. Hasil Topic Modeling Kelas Negatif dengan Latent Dirichlet Allocation (LDA)

| Topik | Kata Kunci | Deskripsi |
|---|---|---|
| Topik 1 | online, hacker, irit, percaya, banget, lucu, bahaya, pemilu, takut, perintah | Kekhawatiran terhadap keamanan sistem pemilu digital akibat ancaman peretasan dan serangan siber. |
| Topik 2 | tuju, main, lawak, tau, pemilu, negara, hasil, pegang, no, ku | Keraguan masyarakat terhadap kredibilitas dan kelayakan penerapan pemilu elektronik. |
| Topik 3 | data, bocor, biar, manipulasi, gampang, mudah, curang, digital, pemilu, pakai | Kekhawatiran mengenai kebocoran data dan potensi manipulasi dalam sistem pemilu digital. |
| Topik 4 | presiden, orang, pilih, akun, langsung, digital, pakai, tau, hp, tebak | Pembahasan terkait mekanisme pemilihan digital dan keterkaitannya dengan aktor politik. |
| Topik 5 | menang, digital, pemilu, suara, indonesia, tau, pilih, langsung, curang, negeri | Kekhawatiran terhadap integritas hasil pemilu, terutama terkait keamanan suara dan legitimasi hasil. |

Hasil topic modeling pada sentimen negatif pada Tabel 3 menunjukkan bahwa pembahasan masyarakat cenderung berfokus pada aspek keamanan, potensi manipulasi data, serta kepercayaan terhadap penerapan pemilu elektronik. Dominasi kata-kata yang berkaitan dengan peretasan, kebocoran data, dan legitimasi hasil pemilu mengindikasikan bahwa kekhawatiran terhadap risiko teknologi masih menjadi salah satu faktor utama yang memengaruhi persepsi negatif masyarakat terhadap pemilu elektronik.

Tabel 4. Hasil Topic Modeling Kelas Positif dengan Latent Dirichlet Allocation (LDA)

| Topik | Kata Kunci | Deskripsi |
|---|---|---|
| Topik 1 | pemilu, pilih, pakai, elektronik, sistem, suara, voting, ktp, data, nik | Dukungan terhadap penerapan pemilu elektronik sebagai sistem pemilihan yang lebih modern, praktis, dan terstruktur. |
| Topik 2 | pemilu, digital, negara, online, konoha, banteng, menang, rakyat, hemat, data | Persepsi positif mengenai efisiensi biaya dan kemudahan akses yang ditawarkan oleh pemilu digital. |
| Topik 3 | pakai, sistem, voting, pemilu, akun, pilih, teknologi, hati, kadang, digital | Pandangan bahwa pemanfaatan teknologi digital dalam pemilu merupakan bentuk kemajuan yang sesuai dengan perkembangan zaman. |
| Topik 4 | kardus, gembok, menang, pakai, langsung, kotak, kemarin, tebak, digital, paham | Harapan terhadap proses pemilu yang lebih cepat, transparan, dan mudah dipahami oleh masyarakat. |
| Topik 5 | biar, irit, menang, mudah, rakyat, no, hemat, langsung, curang, cerdas | Optimisme bahwa pemilu elektronik dapat meningkatkan kemudahan, efisiensi, dan kualitas partisipasi publik. |

Hasil topic modeling Tabel 4 pada sentimen positif didominasi oleh pembahasan mengenai efisiensi, kemudahan akses, dan pemanfaatan teknologi dalam penyelenggaraan pemilu. Dominasi kata-kata yang berkaitan dengan sistem digital, efisiensi biaya, kemudahan penggunaan, dan kemajuan teknologi menunjukkan bahwa sebagian masyarakat memandang pemilu elektronik sebagai inovasi yang berpotensi meningkatkan efektivitas serta kualitas pelaksanaan pemilu di masa mendatang.

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

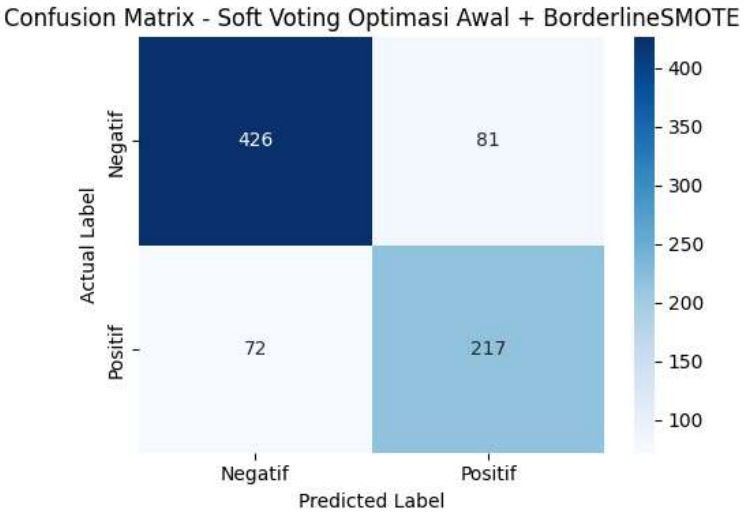
3.4 Evaluation

Tahap evaluation dilakukan untuk mengukur performa model klasifikasi menggunakan confusion matrix dan 5-Fold Cross Validation. Evaluasi dilakukan berdasarkan metrik accuracy, precision, recall, dan F1-score untuk membandingkan performa setiap model pada berbagai skenario pengujian.

Tabel 5. Hasil Evaluasi Skenario Model

| Model | Borderline-SMOTE | Accuracy | Precision | Recall | F1-Score |
|---|---|---|---|---|---|
| Soft Voting Baseline | Ya | 0,7990 | 0,8018 | 0,7990 | 0,8001 |
| Soft Voting Baseline | Tidak | 0,7739 | 0,7793 | 0,7739 | 0,7584 |
| Soft Voting Optimasi Awal | Ya | 0,8078 | 0,8092 | 0,8078 | 0,8084 |
| Soft Voting Optimasi Awal | Tidak | 0,7940 | 0,7919 | 0,7940 | 0,7875 |
| Soft Voting Tuning | Ya | 0,7902 | 0,7929 | 0,7902 | 0,7913 |
| Soft Voting Tuning | Tidak | 0,8003 | 0,8015 | 0,8003 | 0,7917 |
| Logistic Regression Tuning | Tidak | 0,7965 | 0,7945 | 0,7965 | 0,7904 |
| Random Forest Tuning | Tidak | 0,7651 | 0,7801 | 0,7651 | 0,7426 |

Berdasarkan hasil pengujian pada Tabel 5, Soft Voting Ensemble menunjukkan performa yang lebih baik dibandingkan Logistic Regression dan Random Forest. Soft Voting Optimasi Awal dengan Borderline-SMOTE memperoleh akurasi tertinggi sebesar 80,78%, menunjukkan bahwa kombinasi ensemble learning dan Borderline-SMOTE mampu meningkatkan performa klasifikasi sentimen terhadap pemilu elektronik. Hasil ini mengindikasikan bahwa penyeimbangan distribusi kelas pada data latih dapat membantu model mengenali pola sentimen secara lebih optimal, terutama pada kelas minoritas. Selain itu, pendekatan ensemble memungkinkan model memanfaatkan keunggulan dari beberapa algoritma sehingga menghasilkan prediksi yang lebih akurat dibandingkan penggunaan model tunggal.




Gambar 3. Hasil Confusion Matrix Akurasi Terbaik

Gambar 3 menunjukkan confusion matrix dari model Soft Voting Optimasi Awal dengan Borderline-SMOTE yang memperoleh akurasi tertinggi pada penelitian ini. Model mampu mengklasifikasikan sebagian besar data pada kedua kelas dengan tingkat kesalahan yang relatif rendah, yang tercermin dari nilai accuracy, precision, recall, dan F1-score yang diperoleh.

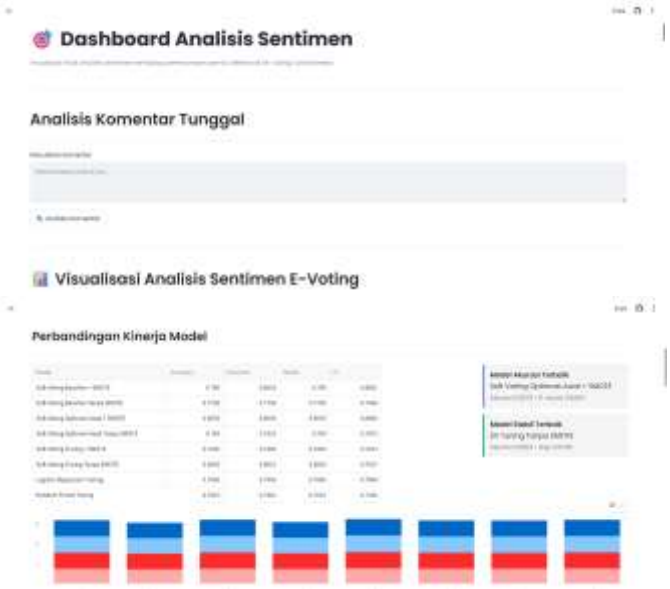
DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Tabel 6. Hasil 5 Fold Cross Validation

| Model | Borderline-SMOTE | Mean Train | Mean Val | CV Gap |
|---|---|---|---|---|
| Soft Voting Baseline | Ya | 0,8659 | 0,7820 | 0,0839 |
| Soft Voting Baseline | Tidak | 0,8195 | 0,7751 | 0,0445 |
| Soft Voting Optimasi Awal | Ya | 0,9008 | 0,7820 | 0,1188 |
| Soft Voting Optimasi Awal | Tidak | 0,8856 | 0,7955 | 0,0901 |
| Soft Voting Tuning | Ya | 0,8596 | 0,7810 | 0,0786 |
| Soft Voting Tuning | Tidak | 0,8579 | 0,7873 | 0,0706 |
| Logistic Regression Tuning | Tidak | 0,8717 | 0,7958 | 0,0759 |
| Random Forest Tuning | Tidak | 0,8100 | 0,7625 | 0,0475 |

Meskipun Soft Voting Optimasi Awal dengan Borderline-SMOTE menghasilkan akurasi tertinggi sebesar 80,78%, hasil 5-Fold Cross Validation menunjukkan bahwa model tersebut memiliki nilai CV Gap sebesar 0,1188. Sementara itu, Soft Voting Tuning tanpa Borderline-SMOTE memperoleh akurasi sebesar 80,03% dengan nilai CV Gap yang lebih kecil, yaitu 0,0706. Hasil ini menunjukkan bahwa Soft Voting Tuning tanpa Borderline-SMOTE memiliki kemampuan generalisasi dan stabilitas yang lebih baik dibandingkan model lainnya. Perbedaan akurasi antara kedua model hanya sebesar 0,75%, namun Soft Voting Tuning tanpa Borderline-SMOTE mampu mempertahankan konsistensi performa yang lebih baik pada setiap fold pengujian. Temuan ini menunjukkan bahwa pemilihan model terbaik tidak hanya perlu mempertimbangkan nilai akurasi, tetapi juga kemampuan model dalam menghasilkan performa yang stabil ketika diterapkan pada data yang berbeda.

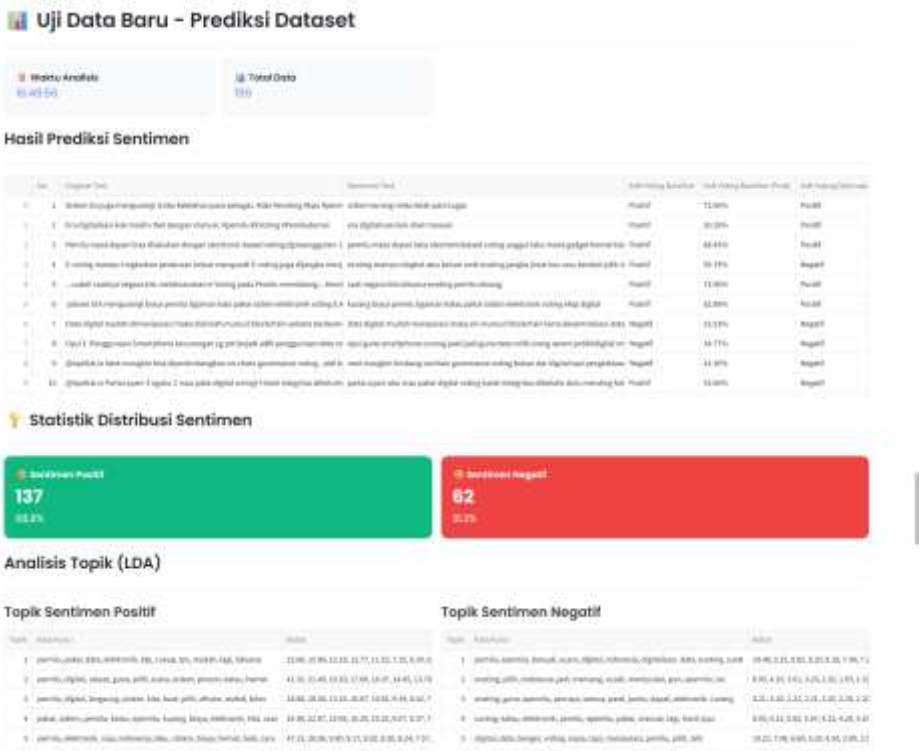
3.5 Deployement




Gambar 4. Implementasi Dashboard Analisis Sentimen Berbasis Streamlit

Gambar 4 menunjukkan implementasi dashboard analisis sentimen berbasis Streamlit yang dikembangkan pada tahap deployment. Dashboard ini dirancang untuk menyajikan hasil analisis sentimen terhadap opini masyarakat mengenai pemilu elektronik secara interaktif dan mudah dipahami. Pengguna dapat melihat visualisasi distribusi sentimen serta perbandingan kinerja model klasifikasi yang meliputi Logistic Regression, Random Forest, dan Soft Voting Ensemble berdasarkan metrik evaluasi yang digunakan dalam penelitian. Melalui visualisasi tersebut, pengguna dapat memperoleh gambaran mengenai performa masing-masing model dan hasil analisis yang telah dilakukan.

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)




Gambar 5. Implementasi Prediksi Sentimen Data Baru pada Dashboard Admin

Gambar 5 menunjukkan fitur prediksi sentimen pada sisi admin yang digunakan untuk menguji data baru di luar dataset penelitian. Admin dapat mengunggah dataset komentar yang akan diproses menggunakan model klasifikasi terbaik yang dihasilkan pada penelitian ini. Hasil prediksi kemudian ditampilkan dalam bentuk tabel yang memuat informasi sentimen untuk setiap komentar yang dianalisis. Fitur ini menunjukkan bahwa model yang dikembangkan tidak hanya digunakan untuk kebutuhan evaluasi penelitian, tetapi juga dapat diimplementasikan untuk melakukan klasifikasi sentimen terhadap data baru secara otomatis.

## 4. Kesimpulan

Penelitian ini berhasil menerapkan metode Soft Voting Ensemble untuk analisis sentimen opini masyarakat terhadap pemilu elektronik di Indonesia menggunakan data komentar X dan TikTok yang diperoleh melalui proses crawling, seleksi data, pelabelan sentimen, text preprocessing, pembobotan TF-IDF, serta penanganan ketidakseimbangan data menggunakan Borderline-SMOTE. Berdasarkan hasil pengujian beberapa skenario model, Soft Voting Optimasi Awal dengan Borderline-SMOTE memperoleh performa terbaik dengan akurasi sebesar 80,78%, yang menunjukkan bahwa kombinasi metode ensemble dan teknik oversampling mampu meningkatkan kemampuan klasifikasi sentimen. Hasil tersebut juga menunjukkan bahwa Soft Voting Ensemble secara umum memiliki performa yang lebih baik dibandingkan Logistic Regression dan Random Forest pada dataset yang digunakan dalam penelitian ini. Meskipun demikian, hasil 5-Fold Cross Validation menunjukkan bahwa Soft Voting Tuning tanpa Borderline-SMOTE memiliki nilai CV Gap yang lebih kecil, yaitu sebesar 0,0706, dibandingkan Soft Voting Optimasi Awal dengan Borderline-SMOTE yang memiliki CV Gap sebesar 0,1188. Temuan ini mengindikasikan bahwa Soft Voting Tuning tanpa Borderline-SMOTE memiliki kemampuan generalisasi dan stabilitas yang lebih baik ketika dihadapkan pada data yang berbeda. Dengan demikian, hasil penelitian menunjukkan bahwa pemilihan model terbaik tidak hanya ditentukan oleh nilai akurasi tertinggi, tetapi juga perlu mempertimbangkan konsistensi performa dan kemampuan generalisasi model. Penelitian ini juga berhasil menerapkan metode Latent Dirichlet Allocation (LDA) untuk mengidentifikasi topik-topik dominan yang muncul pada masing-masing kelas sentimen. Hasil topic modeling pada sentimen negatif menunjukkan bahwa opini masyarakat banyak dipengaruhi oleh isu keamanan sistem, ancaman peretasan, kebocoran data, potensi manipulasi, serta keabsahan hasil pemilu elektronik. Sebaliknya, topic modeling pada sentimen positif menunjukkan bahwa masyarakat memandang pemilu elektronik sebagai inovasi yang mampu meningkatkan efisiensi, kemudahan akses, modernisasi sistem pemilu, serta pemanfaatan teknologi digital dalam proses demokrasi. Temuan tersebut menunjukkan bahwa persepsi masyarakat terhadap pemilu elektronik tidak hanya

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

terbagi ke dalam sentimen positif dan negatif, tetapi juga dipengaruhi oleh berbagai isu yang menjadi perhatian utama publik. Pada tahap deployment, hasil penelitian berhasil diimplementasikan ke dalam dashboard berbasis Streamlit yang mampu menyajikan visualisasi analisis sentimen, perbandingan performa model, hasil topic modeling, serta prediksi sentimen terhadap data baru secara interaktif. Implementasi tersebut menunjukkan bahwa model yang dikembangkan tidak hanya memiliki performa yang baik pada tahap pengujian, tetapi juga dapat diterapkan sebagai sarana analisis opini masyarakat secara lebih efektif dan informatif. Dengan demikian, penelitian ini memberikan kontribusi dalam pemanfaatan teknik machine learning dan topic modeling untuk memahami persepsi masyarakat terhadap penerapan pemilu elektronik di Indonesia.

## Referensi

[1] M. T. Junindri, Gusliana, and M. Rauf, "Pengaturan Electronic Voting ( E-Voting ) Sebagai Perwujudan Asas Langsung, Umum, Bebas, Rahasia, Jujur dan Adil Dalam Pemilihan Umum (Pemilu ) Ditinjau Dari Sistem Ketatanegaraan Indonesia," *J. Ilm. Wahana Pendidik.*, vol. 10, pp. 773–781, 2024.

[2] A. Setiawan, "Penerapan Sistem E-Voting Pada Era Society 5.0 Sebagai Hasil Putusan Mahkamah Konstitusi Nomor 147/Puu-Vii/2009," *Maj. Huk. Nas.*, vol. 53, no. 1, pp. 50–71, 2023.

[3] M. R. Adipratama and N. Safriadi, "Analisis Sentimen Terhadap Rencana Penerapan E-Voting Pada Pemilu di Indonesia," *J. Linguist. Komputasional*, vol. 7, no. 1, pp. 26–30, 2024, doi: 10.26418/jlk.v7i1.214.

[4] D. Ardiansyah, A. Saepudin, R. Aryanti, E. Fitriani, and Royadi, "Analisis Sentimen Review Pada Aplikasi Media Sosial Tiktok Menggunakan Algoritma K-Nn Dan Svm Berbasis Pso," *J. Inform. Kaputama*, vol. 7, no. 2, pp. 233–241, 2023, doi: 10.59697/jik.v7i2.148.

[5] P. B. Patil, "Sentiment Analysis in Twitter Data 1," vol. 10, no. 7, pp. 539–543, 2022.

[6] A. Arham, E. R. Swedia, M. Cahyanti, and M. R. D. Septian, "Implementasi Sentiment Analysis Pada Opini Masyarakat Indonesia Di Twitter Terhadap Virus Covid-19 Varian Omicron Dengan Algoritma Naïve Bayes, Decision Tree, Dan Support Vector Machine," *Sebatik*, vol. 26, no. 2, pp. 565–572, 2022, doi: 10.46984/sebatik.v26i2.1961.

[7] I. P. D. W. Darmawan, G. A. Pradnyana, and I. B. N. Pascima, "Optimasi Parameter Support Vector Machine Dengan Algoritma Genetika Untuk Analisis Sentimen Pada Media Sosial Instagram," *SINTECH (Science Inf. Technol. J.*, vol. 6, no. 1, pp. 58–67, 2023, doi: 10.31598/sintechjournal.v6i1.1245.

[8] S. A. Assaidi and F. Amin, "Analisis Sentimen Evaluasi Pembelajaran Tatap Muka 100 Persen pada Pengguna Twitter menggunakan Metode Logistic Regression," *J. Pendidik. Tambusai*, vol. 6, no. 2, pp. 13217–13227, 2022.

[9] M. R. F. Rahmatullah, P. N. Andono, and M. A. Soeleman, "Improving Random Forest Performance for Sentiment Analysis on Unbalanced Data Using SMOTE and BoW Integration : PLN Mobile Application Case Study," vol. 12, no. 1, pp. 1–10, 2025, doi: 10.15294/sji.v12i1.19295.

[10] S. R. Aisy and B. Prasetiyo, "Sentiment Analysist of the TPKS Law on Twitter Using InSet Lexicon with Multinomial Naïve Bayes and Support Vector Machine Based on Soft Voting," *Recursive J. Informatics*, vol. 1, no. 2, pp. 93–101, 2023, doi: 10.15294/rji.v1i2.68324.

[11] M. Ma'ruf, A. P. Kuncoro, P. Subarkah, and F. Nida, "Sentiment analysis of customer satisfaction levels on smartphone products using Ensemble Learning," *Ilk. J. Ilm.*, vol. 14, no. 3, pp. 339–347, 2022, doi: 10.33096/ilkom.v14i3.1377.339-347.

[12] A. A. Ilham, E. Warni, and Pahrul, "Soft Voting Classifier With Optimized Weight Using Particle Swarm Optimization on Sentiment Analysis for Online Credit and Loan Application Reviews," *Int. J. Innov. Comput. Inf. Control*, vol. 20, no. 2, pp. 359–372, 2024, doi: 10.24507/ijicic.20.02.359.

[13] T. Triwiyanto, A. Rizal, and W. Caesarendra, *Proceeding of the 3rd International Conference on Electronics, Biomedical Engineering, and Health Informatics*, vol. 1008. 2023. [Online]. Available: https://link.springer.com/10.1007/978-981-99-0248-4

[14] T. D. Dikiyanti, A. M. Rukmi, and M. I. Irawan, "Sentiment analysis and topic modeling of BPJS Kesehatan based on twitter crawling data using Indonesian Sentiment Lexicon and Latent Dirichlet Allocation algorithm," *J. Phys. Conf. Ser.*, vol. 1821, no. 1, 2021, doi: 10.1088/1742-6596/1821/1/012054.

[15] R. R. Salam, M. F. Jamil, Y. Ibrahim, R. Rahmaddeni, S. Soni, and H. Herianto, "Analisis Sentimen Terhadap Bantuan Langsung Tunai (BLT) Bahan Bakar Minyak (BBM) Menggunakan Support Vector Machine," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 1, pp. 27–35, 2023, doi: 10.57152/malcom.v3i1.590.

[16] Y. A. Prasetyo, E. Utami, and A. Yaqin, "Pengaruh Komposisi Split Data Terhadap Performa Akurasi Analisis Sentimen Algoritma Naïve Bayes dan SVM," vol. 6, no. 2, pp. 382–390, 2024, doi: 10.33650/jeecom.v4i2.

[17] R. Arifudin, D. Indra Wijaya, B. Warsito, and A. Wibowo, "Voting Classifier Technique and Count Vectorizer with N-gram to Identify Hate Speech and Abusive Tweets in Indonesian," *Sci. J. Informatics*, vol. 10, no. 4, p. 469, 2023, doi: 10.15294/sji.v10i4.46633.

[18] N. Sedana, S. Wijaya, and R. Artana, "ENGLISH SENTIMENT ANALYSIS USING THE LSTM METHOD CASE STUDY OF," vol. 11, no. 6, 2024, doi: 10.25126/jtiik.2024118792.

DOI: https://doi.org/10.31004/riggs.v5i2.10298
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)