

Peningkatan Akurasi *Naïve Bayes* dengan *Particle Swarm Optimization* dalam Analisis Sentimen Ibu Kota Nusantara (IKN)

Improving Naïve Bayes Accuracy with Particle Swarm Optimization in Sentiment Analysis of Ibu Kota Nusantara (IKN)

Irma Surya Kumala Idris
Program Studi Teknik Informatika
Universitas Ichsan Gorontalo
Gorontalo, Indonesia
mhaladp@gmail.com

Yasin Aril Mustofa*
Program Studi Informatika
Universitas Ichsan Sidenreng Rappang
Sidrap, Indonesia
arieldcc@gmail.com

Diterima : Mei 2025
Disetujui : Juni 2025
Dipublikasi : Juli 2025

Abstrak—Pembangunan Ibu Kota Nusantara (IKN) menimbulkan diskursus publik yang luas di media sosial, menjadikan analisis sentimen sebagai pendekatan strategis untuk memahami opini masyarakat. Studi ini mengevaluasi kinerja algoritma *Naïve Bayes* yang ditingkatkan menggunakan pendekatan *Particle Swarm Optimization* (PSO) dalam tugas pengelompokan sentimen publik terhadap proyek IKN, dengan menggunakan data komentar berbahasa Indonesia dari platform media sosial X. Hasil awal dari model *Naïve Bayes* standar mencatat akurasi sebesar 78,3%, sedangkan setelah proses optimasi dengan PSO, akurasi meningkat menjadi 79,7% pada pengaturan parameter terbaik. Hasil ini memperlihatkan potensi PSO dalam meningkatkan efektivitas seleksi fitur dan mengurangi kesalahan klasifikasi, terutama pada sentimen positif. Meski pendekatan ini menunjukkan perbaikan, keterbatasan seperti ketergantungan pada pelabelan otomatis dan konteks linguistik masih menjadi tantangan. Studi ini memberikan kontribusi awal dalam pengembangan metode klasifikasi opini publik berbasis optimasi, serta mendorong eksplorasi pendekatan lanjutan seperti *deep learning* untuk konteks bahasa Indonesia.

Kata Kunci—*Naïve Bayes; Particle Swarm Optimization; Analisis Sentimen; Ibu Kota Nusantara.*

Abstract—The development of Indonesia's new capital city, Ibu Kota Nusantara (IKN), has sparked extensive public discourse on social media, positioning sentiment analysis as a strategic approach to understanding public opinion. This study assesses the performance of the *Naïve Bayes* algorithm enhanced through *Particle Swarm Optimization* (PSO) in classifying public sentiment related to the IKN project, using Indonesian-language comments extracted from the social media platform X. The initial *Naïve Bayes* model achieved an accuracy of 78.3%, while the PSO-optimized model demonstrated an improved accuracy of 79.7% under optimal parameter settings. These findings indicate the potential of PSO to enhance feature selection effectiveness and

reduce classification errors, particularly for positive sentiments. Despite the observed improvements, limitations such as reliance on automated sentiment labeling and challenges posed by linguistic context remain. This study contributes an early exploration of optimization-based methods for public opinion classification and highlights the need for further research involving advanced approaches such as *deep learning* tailored to the Indonesian language.

Keywords—*Naïve Bayes; Particle Swarm Optimization; Sentiment Analysis; Nusantara Capital City.*

I. PENDAHULUAN

Pembangunan Ibu Kota Negara (IKN) Nusantara sebagai pengganti Jakarta telah memicu perdebatan luas di ruang publik, khususnya melalui media sosial. Kebijakan ini bukan hanya dipandang sebagai perpindahan administratif, tetapi juga sebagai simbol transformasi nasional yang memuat dimensi lingkungan, ekonomi, sosial, dan politik. Di era digital, media sosial seperti X dan Facebook menjadi saluran utama masyarakat dalam mengekspresikan dukungan, kritik, dan kekhawatiran terhadap proyek ini. Reaksi publik yang terekam mencerminkan kompleksitas persepsi masyarakat terhadap keberlanjutan lingkungan, beban fiskal negara, serta representasi identitas nasional dalam konteks relokasi ibu kota [1], [2], [3].

Studi sebelumnya menunjukkan bahwa opini publik yang positif terhadap Nusantara umumnya terkait harapan akan perbaikan dari kondisi lingkungan Jakarta yang selama ini mengalami degradasi seperti banjir dan polusi udara [4], [5]. Namun, sentimen positif ini kerap dibayangi oleh kritik terhadap minimnya sosialisasi dari pemerintah yang menimbulkan kesalahpahaman publik [6], [7]. Di sisi lain, penyebaran informasi keliru atau hoaks juga memperkeruh

wacana di media sosial, memperlihatkan campuran antara sentimen optimistik dan skeptis dalam diskursus masyarakat [8]. Aspek ekonomi pun menjadi sorotan tajam, terutama terkait prioritas anggaran di tengah pemulihan pasca pandemi [9], [10].

Dalam konteks ini, analisis sentimen berperan sebagai alat penting untuk menilai pandangan publik secara terstruktur. Pendekatan ini memungkinkan pengolahan data berskala besar guna mendeteksi dan mengklasifikasikan opini menjadi tiga kategori: positif, negatif, atau netral. Tahapan analisis meliputi pengambilan data dari media sosial, pembersihan teks, pemecahan kata (tokenisasi), normalisasi, hingga proses klasifikasi sentimen [11], [12]. Algoritma seperti *Naïve Bayes* dan *Support Vector Machine* (SVM) telah banyak digunakan untuk tugas ini karena kemampuannya dalam menangani teks yang tidak terstruktur dengan akurasi tinggi [13]. Hasil analisis ini tidak hanya penting untuk memetakan pola persepsi publik, tetapi juga memberikan masukan yang berbasis data bagi para pembuat kebijakan dalam merespon kekhawatiran masyarakat secara tepat waktu. Bagi masyarakat, informasi ini dapat meningkatkan transparansi dan pemahaman kolektif terhadap isu strategis nasional seperti pembangunan IKN.

Naïve Bayes dikenal karena efisiensinya dalam pemrosesan cepat dan hasil klasifikasi yang memadai meskipun menghadapi data dalam jumlah besar [14], [15]. Namun, kelemahannya yang utama adalah asumsi independensi antar fitur dan sensitivitas terhadap ketidakseimbangan data [16]. Untuk mengatasi hal ini, studi ini mengintegrasikan *Particle Swarm Optimization* (PSO) dalam proses klasifikasi untuk seleksi fitur yang lebih optimal. PSO merupakan algoritma metaheuristik yang meniru perilaku kolektif seperti kawanan burung, yang bertujuan mencari solusi terbaik dalam ruang pencarian [17]. Kombinasi ini dipilih karena karakteristik data media sosial Indonesia yang cenderung tidak terstruktur, informal, dan kaya akan variasi linguistik, sehingga membutuhkan pendekatan yang adaptif dan efisien. Dengan menggabungkan kesederhanaan dan kecepatan *Naïve Bayes* serta kemampuan eksplorasi solusi optimal dari PSO, model ini diharapkan dapat meningkatkan akurasi klasifikasi sekaligus mempertahankan efisiensi komputasi dalam skala data besar seperti komentar media sosial.

Fokus utama studi ini adalah membandingkan dan mengevaluasi performa algoritma *Naïve Bayes* konvensional dengan versi yang telah ditingkatkan melalui optimasi *Particle Swarm Optimization* (PSO), dalam menganalisis sentimen publik terhadap proyek pembangunan IKN menggunakan data komentar dari platform media sosial *X*. Fokus utama terletak pada tahapan *preprocessing*, pelabelan sentimen menggunakan *TextBlob*, serta evaluasi akurasi model melalui *confusion matrix*. Studi sebelumnya umumnya menerapkan PSO dalam domain bahasa Inggris atau pada topik umum seperti produk dan layanan, namun belum banyak yang mengadopsinya untuk isu kebijakan publik dalam konteks lokal berbahasa Indonesia. Kebaruan dari studi ini terletak pada penerapan PSO sebagai teknik seleksi fitur dalam klasifikasi opini publik terkait kebijakan strategis nasional, khususnya pembangunan IKN, yang datanya diambil dari *platform* media sosial dengan karakteristik teks pendek dan informal. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan metode analisis opini publik yang lebih

adaptif terhadap dinamika sosial digital Indonesia, serta mendukung perumusan kebijakan berbasis data yang lebih kontekstual dan responsif.

II. METODE

Penelitian ini menerapkan metode eksperimen kuantitatif untuk membandingkan efektivitas algoritma *Naïve Bayes* konvensional dan versi yang dioptimalkan melalui teknik *Particle Swarm Optimization* (PSO) dalam menganalisis sentimen publik mengenai proyek Ibu Kota Nusantara. Data yang digunakan dikumpulkan dari platform media sosial *X* yang merepresentasikan opini masyarakat dalam format teks singkat berbahasa Indonesia. Proses metodologi melibatkan lima tahapan utama, yaitu pengumpulan data, pra-pemrosesan data, pelabelan sentimen, pembobotan fitur, serta pembangunan dan evaluasi model klasifikasi.

A. Pengumpulan Data

Data diperoleh dari platform media sosial *X* dengan menggunakan kata kunci "Ibu Kota Nusantara". Pengumpulan dilakukan menggunakan teknik *crawling* berbasis *Application Programming Interface* (API). Dari hasil pengumpulan awal, diperoleh 1.364 komentar. Setelah melalui tahap filtrasi untuk memastikan relevansi dan kejelasan bahasa, hanya 1.129 komentar berbahasa Indonesia yang digunakan sebagai dataset akhir. Data ini mencerminkan opini publik yang aktual dan dinamis terkait isu pemindahan ibu kota.

B. Pra-pemrosesan Data

Pra-pemrosesan menjadi langkah krusial untuk memperbaiki kualitas data teks sebelum diterapkan pada model *machine learning*. Karena bahasa Indonesia memiliki ciri khas seperti penggunaan imbuhan, bahasa gaul, dan keberagaman dialek, dibutuhkan metode penanganan yang disesuaikan dalam proses ini. Tahapan pra-pemrosesan meliputi:

- *Case Folding*

Seluruh karakter diubah menjadi huruf kecil untuk menghilangkan perbedaan akibat kapitalisasi. Teknik ini penting untuk konsistensi dan pengenalan pola dalam data teks [18], [19].

- Tokenisasi

Teks dibagi menjadi token atau kata-kata tunggal. Penggunaan *tokenizer* yang memahami struktur bahasa informal Indonesia termasuk *emotikon*, *hashtag*, dan singkatan meningkatkan pemahaman konteks [20].

- *Stopword Removal*

Kata-kata umum seperti "yang", "dan", "di" dihilangkan karena tidak berkontribusi secara signifikan terhadap makna sentimen. Penghapusan *stopword* membantu fokus model pada kata-kata bermakna [21].

- *Stemming*

Kata-kata dikembalikan ke bentuk dasar menggunakan algoritma Nazief dan Adriani, yang terbukti efektif menangani morfologi bahasa Indonesia [16].

- Normalisasi

Proses ini mencakup perbaikan kesalahan penulisan, transformasi angka ke bentuk kata, dan penyeragaman bentuk kata informal. *Slang* dan variasi ejaan diidentifikasi dan distandarkan menggunakan kamus *slang* dan algoritma *Levenshtein* [12], [22].

- Emotikon dan *Hashtag*

Komponen ini diterjemahkan ke dalam representasi sentimen sesuai konteks. Misalnya, emoji senyum diklasifikasikan sebagai positif, dan *hashtag* seperti #dukungIKN dikenali sebagai indikator opini [19].

C. Pelabelan Sentimen

Komentar berbahasa Indonesia yang telah melalui tahap pra-pemrosesan diterjemahkan ke dalam bahasa Inggris untuk kemudian dianalisis menggunakan pustaka *TextBlob* guna klasifikasi sentimen ke dalam kategori positif atau negatif. Pendekatan ini dipilih karena kemampuannya dalam memproses data dalam jumlah besar secara cepat dan otomatis. Namun demikian, metode ini memiliki keterbatasan signifikan dalam konteks lokal, terutama risiko hilangnya makna, nuansa emosional, serta ekspresi budaya seperti *slang*, *sarkasme*, atau *idiom* lokal yang umum di media sosial Indonesia. Selain itu, akurasi *TextBlob* dalam menangani kalimat kompleks atau ironis relatif rendah. Oleh karena itu, penggunaan model lokal berbasis Bahasa Indonesia seperti *IndoBERT*, *IndoNLU*, atau model *sentiment analysis* yang telah dilatih secara khusus pada data Indonesia disarankan untuk penelitian lanjutan agar dapat meningkatkan relevansi dan ketepatan klasifikasi dalam konteks linguistik yang lebih sesuai.

D. Pembobotan Fitur

Teknik *Term Frequency-Inverse Document Frequency* (TF-IDF) digunakan untuk mentransformasi hasil pra-pemrosesan teks menjadi representasi numerik yang kompatibel dengan model pembelajaran mesin. Pendekatan ini memprioritaskan kata-kata yang memiliki frekuensi tinggi dalam satu dokumen tetapi jarang muncul di seluruh korpus, sehingga dianggap memiliki bobot informasi yang lebih signifikan. Pendekatan ini berperan dalam meminimalkan pengaruh kata-kata umum yang tidak memiliki nilai signifikan dalam proses klasifikasi sentimen [23], [24].

TF-IDF dibangun dari dua elemen utama, yaitu:

- *Term Frequency* (TF)

Mengukur frekuensi kemunculan suatu istilah t dalam dokumen tertentu d , yang diperoleh melalui perhitungan dengan formula sebagai berikut:

$$TF(t, d) = \frac{f_{t,d}}{\sum_k f_{k,d}} \quad (1)$$

Dalam hal ini $f_{t,d}$ merujuk pada jumlah kemunculan kata t dalam dokumen d , sementara $\sum_k f_{k,d}$ menunjukkan total seluruh kata yang terdapat dalam dokumen tersebut.

- *Inverse Document Frequency* (IDF)

Menilai tingkat kepentingan sebuah *term* di seluruh kumpulan dokumen, yang dihitung menggunakan rumus berikut:

$$IDF(t) = \log\left(\frac{N}{1+n_t}\right) \quad (2)$$

Dalam hal ini, N mewakili jumlah keseluruhan dokumen dalam korpus, sementara n_t menunjukkan banyaknya dokumen yang memuat *term* t . Penambahan angka 1 pada penyebut bertujuan untuk mencegah terjadinya pembagian dengan nol.

Skor akhir TF-IDF diperoleh dari hasil perkalian keduanya:

$$TF-IDF(t, d) = TF(t, d) \times IDF(t) \quad (3)$$

Persamaan (3) memungkinkan pemodelan untuk lebih fokus pada kata-kata yang memiliki kontribusi signifikan terhadap makna sentimen dan menghindari kata-kata umum yang bersifat netral atau tidak informatif secara emosional.

Dalam penelitian ini, TF-IDF dipilih karena memberikan keseimbangan antara efisiensi komputasi dan akurasi klasifikasi, dibandingkan dengan pendekatan lain seperti *Term Frequency-Rank Frequency* (TF-RF) atau *Word2Vec*. Meskipun metode alternatif tersebut memiliki keunggulan dalam konteks tertentu, TF-IDF tetap menjadi metode yang andal dalam representasi fitur untuk data teks berskala besar dan tidak terstruktur seperti tweet [23].

E. Pembangunan dan Evaluasi Model

Model klasifikasi dibangun menggunakan dua pendekatan:

- *Naive Bayes* Standar

Algoritma *Naive Bayes* tergolong ke dalam pendekatan klasifikasi yang menggunakan prinsip probabilistik, dengan asumsi bahwa setiap fitur saling bebas satu sama lain dalam konteks prediksi kelas. Model ini menghitung probabilitas dari setiap kelas C terhadap fitur x_1, x_2, \dots, x_n dengan rumus:

$$P(C | x_1, x_2, \dots, x_n) = \frac{P(C) \prod_{i=1}^n P(x_i | C)}{P(x_1, x_2, \dots, x_n)} \quad (4)$$

Persamaan (4) bergantung pada estimasi distribusi dari setiap fitur terhadap kelas yang diamati. *Naive Bayes* dikenal karena efisiensinya dan sering digunakan dalam analisis sentimen di media sosial dengan tingkat akurasi yang kompetitif [12], [25], [26], [27]. Namun, keterbatasan utama *Naive Bayes* terletak pada asumsi independensi fitur dan sensitivitas terhadap data *sparsity* serta ketidakseimbangan kelas [28].

- *Naive Bayes* + PSO

Sebagai upaya untuk mengatasi keterbatasan tersebut, diterapkan metode *optimasi Particle Swarm Optimization* (PSO) dalam proses seleksi fitur guna meningkatkan ketepatan klasifikasi. PSO merupakan algoritma metaheuristik yang mengadopsi prinsip pergerakan kolektif seperti kawanan burung atau ikan. Dalam algoritma ini, setiap partikel mewakili solusi yang mungkin dan bergerak di dalam ruang pencarian dengan mempertimbangkan pengalaman terbaiknya sendiri (*pBest*) serta pengalaman terbaik dari seluruh populasi (*gBest*). Pergerakan partikel dikendalikan melalui pembaruan posisi dan kecepatan menggunakan rumus tertentu.

$$v_i^{t+1} = wv_i^t + c_1r_1(pbBest_i - x_i^t) + c_2r_2(gBest - x_i^t) \quad (5)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (6)$$

Dengan:

v_i : kecepatan partikel ke- i

x_i : posisi partikel ke- i

w : bobot inersia

c_1, c_2 : konstanta pembelajaran

r_1, r_2 : bilangan acak dalam $[0,1]$

Proses optimasi parameter *smoothing* pada *Naive Bayes* dengan PSO dijelaskan secara sistematis dalam *pseudocode* yang ditampilkan pada Gambar 1. *Pseudocode* tersebut menggambarkan bagaimana setiap partikel merepresentasikan nilai kandidat parameter α yang dievaluasi melalui akurasi klasifikasi, serta bagaimana partikel menavigasi ruang pencarian berdasarkan nilai terbaik personal ($pBest$) dan global ($gBest$).

PSO mengoptimalkan subset fitur dari hasil representasi TF-IDF dengan menyesuaikan parameter jumlah populasi, jumlah generasi, dan bobot inersia. Parameter ini diuji dalam beberapa konfigurasi untuk mencari kombinasi optimal yang memberikan akurasi tertinggi.

Algorithm 1: PSO Optimization of Naive Bayes Smoothing Parameter (α)

Input: X : TF-IDF feature matrix
 y : Target labels
 N : Number of particles
 $max.iter$: Number of iterations
 $\alpha.range$: $[0.01, 10]$
Output: $best.alpha, best.model$

- 1 Initialize position, velocity, and fitness for each particle;
- 2 Set $pbest_i = position_i$ for all i ;
- 3 Set $gbest = best\ of\ pbest_i$;
- 4 **for** $t = 1$ **to** $max.iter$ **do**
- 5 **for each particle** i **do**
- 6 Update velocity:
- 7 $velocity_i \leftarrow w \cdot velocity_i + c_1 \cdot rand() \cdot (pbest_i - position_i) + c_2 \cdot rand() \cdot (gbest - position_i)$;
- 8 Update position: $position_i \leftarrow position_i + velocity_i$;
- 9 Train Naive Bayes model with $\alpha = position_i$;
- 10 Evaluate: $fitness_i \leftarrow -accuracy(y.test, y.pred)$;
- 11 **if** $fitness_i$ **better than** $pbest_i$ **then**
- 12 Update $pbest_i$
- 13 Update $gbest$
- 14 **return** $gbest, best\ trained\ model$

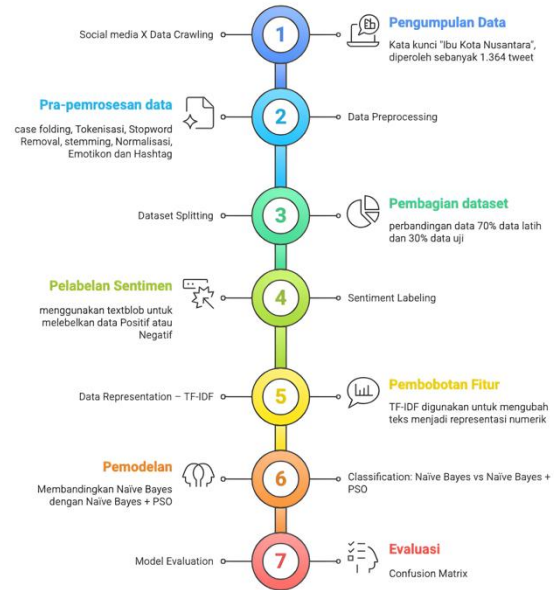
Gambar 1. *Pseudocode* Optimasi Parameter *Smoothing* pada *Naive Bayes* Menggunakan PSO

Gambar 2 menggambarkan tahapan metodologis dalam pelatihan model yang digunakan pada studi ini, dimulai dari akuisisi data hingga proses penilaian kinerja. Pada tahap awal, data dikumpulkan melalui proses *crawling* menggunakan kata kunci "Ibu Kota Nusantara" yang menghasilkan 1.364 komentar. Selanjutnya, dilakukan pra-pemrosesan data yang mencakup *case folding*, tokenisasi, penghapusan *stopword*, *stemming*, normalisasi, serta penanganan *emotikon* dan *hashtag* untuk memastikan kualitas data yang optimal.

Setelah tahap pra-pemrosesan, data dibagi menjadi dua bagian, yaitu 70% untuk pelatihan dan 30% untuk pengujian, dengan pendekatan stratified sampling untuk menjaga proporsi sentimen tetap seimbang [14]. Pada tahap pelabelan sentimen, digunakan *library TextBlob* untuk

mengklasifikasikan komentar ke dalam kategori positif atau negatif

Tahapan selanjutnya melibatkan proses pembobotan fitur dengan memanfaatkan pendekatan *TF-IDF*, yang bertujuan mentransformasikan data teks ke dalam format numerik agar dapat diolah oleh model pembelajaran mesin. Pemodelan dilakukan dengan cara membandingkan kinerja antara algoritma *Naive Bayes* biasa dan versi yang telah diperkuat melalui optimasi dengan *PSO*. Evaluasi akhir dari model dilakukan menggunakan *confusion matrix* serta beberapa indikator performa lainnya untuk menilai sejauh mana *PSO* berhasil meningkatkan ketepatan klasifikasi sentimen.



Gambar 2. Alur Penelitian

III. HASIL DAN PEMBAHASAN

Tujuan dari studi ini adalah untuk menganalisis dan membandingkan performa algoritma *Naive Bayes* (NB) dengan versi yang telah disempurnakan melalui *Particle Swarm Optimization* (PSO), dalam mengkaji respons publik terhadap proyek Ibu Kota Nusantara (IKN), berdasarkan data yang dikumpulkan dari media sosial X. Pengujian dilakukan pada dua model utama, yakni NB standar dan NB+PSO, dengan variabel eksperimen berupa parameter PSO ukuran populasi, jumlah generasi, dan bobot inersia.

A. Pembobotan Fitur

Dalam penelitian ini, metode *Term Frequency-Inverse Document Frequency* (TF-IDF) diterapkan untuk mengkonversi teks menjadi representasi numerik, dengan memberikan bobot tinggi pada istilah yang sering muncul dalam satu dokumen tetapi jarang ditemukan di keseluruhan kumpulan data [21], [23], [24]. Tujuannya adalah untuk mengidentifikasi *term-term* yang dianggap lebih relevan dan bermakna dalam proses klasifikasi sentimen.

Gambar 3 menampilkan hasil perhitungan bobot TF-IDF dari dua belas *term* terhadap sepuluh dokumen. Terlihat bahwa *term* seperti "desain" (0.284 pada D1) dan "aiiptu" (0.568 pada D4) menjadi *term* dominan dalam dokumen masing-masing, yang menunjukkan kontribusi penting terhadap pemetaan sentimen. Beberapa *term* dengan bobot

lebih kecil, seperti “champ” (0.078), tetap memiliki arti karena dapat menangkap nuansa sentimen tersembunyi dalam data pada media sosial X yang bersifat pendek dan informal.

Sementara itu, Gambar 4 menunjukkan sepuluh *term* dengan rata-rata nilai TF-IDF tertinggi. Kata “ikn” menempati posisi teratas, diikuti oleh “bangun” dan “dokterita”. Hasil ini mempertegas pentingnya fitur-fitur tersebut dalam klasifikasi, sekaligus membuktikan efektivitas metode TF-IDF dalam menyaring informasi bermakna untuk model *Naive Bayes* [12], [21].

No	Terms	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10
0	1	achfahmi	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.074000	0.000000	0.000000
1	2	alipitu	0.000000	0.000000	0.000000	0.568000	0.000000	0.000000	0.000000	0.000000	0.000000
2	3	amp	0.000000	0.000000	0.130000	0.000000	0.000000	0.000000	0.000000	0.144000	0.000000
3	4	apa	0.000000	0.000000	0.000000	0.000000	0.000000	0.568000	0.000000	0.000000	0.000000
4	5	arbainrambey	0.000000	0.000000	0.000000	0.000000	0.000000	0.568000	0.000000	0.000000	0.000000
5	6	atm	0.000000	0.000000	0.000000	0.000000	0.000000	0.074000	0.000000	0.000000	0.000000
6	7	babazada	0.000000	0.131000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
7	8	bangun	0.000000	0.000000	0.130000	0.000000	0.099000	0.000000	0.000000	0.000000	0.000000
8	9	champ	0.000000	0.000000	0.000000	0.000000	0.078000	0.000000	0.000000	0.000000	0.000000
9	10	desain	0.284000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
10	11	dil	0.000000	0.000000	0.000000	0.000000	0.078000	0.000000	0.000000	0.000000	0.000000
11	12	dishubkotsi	0.000000	0.000000	0.000000	0.000000	0.000000	0.074000	0.000000	0.000000	0.000000

Gambar 3. Hitung TF-IDF



Gambar 4. Kata penting berdasarkan TF-IDF

B. Naive Bayes Tanpa PSO

Sebagai langkah awal, model *Naive Bayes* (NB) tanpa optimasi dijalankan sebagai acuan dasar (*baseline*). Dataset yang digunakan sebelumnya telah diproses melalui tahapan pra-pemrosesan dan direpresentasikan menggunakan teknik TF-IDF. Berdasarkan hasil pengujian, model ini memperoleh tingkat akurasi sebesar 78,3%. Berdasarkan *confusion matrix*, model mampu mengklasifikasikan komentar dengan cukup baik, namun masih terdapat sejumlah kesalahan klasifikasi, terutama pada kelas sentimen negatif yang cenderung memiliki nilai *False Negative* tinggi. Hal ini sesuai dengan temuan [24], yang mencatat bahwa NB memiliki keterbatasan dalam menangani data yang tidak seimbang dan sparsitas tinggi pada komentar pendek.

C. Population Size


Eksperimen terhadap ukuran populasi dalam algoritma PSO dilakukan untuk menilai pengaruhnya terhadap akurasi klasifikasi dan jumlah fitur terpilih. Variasi ukuran populasi yang diuji mencakup 10, 30, 50, 70, dan 100 partikel. Hasil eksperimen disajikan dalam TABEL I yang menunjukkan bahwa ukuran populasi 70 menghasilkan akurasi tertinggi sebesar 0.7109 dengan jumlah fitur terpilih sebanyak 1815. Ukuran populasi terlalu kecil (10) menghasilkan akurasi rendah (0.6903), sementara populasi terlalu besar (100) menurunkan akurasi menjadi 0.6991.

Visualisasi dari tren tersebut ditampilkan pada Gambar 5. Pengaruh Ukuran Populasi terhadap Akurasi dan Jumlah Fitur Terpilih, yang memperlihatkan bahwa peningkatan

ukuran populasi awalnya meningkatkan akurasi dan efisiensi seleksi fitur, namun pada titik tertentu justru menimbulkan penurunan performa. Hal ini terjadi karena pada ukuran populasi kecil (misalnya 10), ruang pencarian menjadi terbatas sehingga peluang partikel untuk menjelajahi solusi yang lebih baik sangat rendah, yang menyebabkan konvergensi prematur ke solusi lokal. Ketika ukuran populasi bertambah hingga titik optimal (seperti pada 70 partikel), keseimbangan antara eksplorasi dan eksploitasi tercapai, memungkinkan partikel mengeksplorasi lebih banyak kemungkinan konfigurasi fitur tanpa kehilangan fokus pencarian. Namun, pada populasi yang terlalu besar (misalnya 100), meskipun ruang eksplorasi makin luas, kerumitan koordinasi antar partikel meningkat dan waktu konvergensi melambat, yang dapat menyebabkan penyebaran solusi terlalu luas dan kurang terkonsentrasi, sehingga model kehilangan efisiensi dalam menemukan solusi terbaik secara tepat waktu. Hal ini sejalan dengan literatur yang menyatakan bahwa populasi sedang memberikan keseimbangan antara eksplorasi dan eksploitasi, serta menghindari *overfitting* dan kompleksitas komputasi yang berlebih dalam proses optimasi berbasis *swarm*.

TABEL I. EKSPERIMEN *POPULATION SIZE*

Population Size	Accuracy	Selected Features
10.0	0.6903	1795.0
30.0	0.708	1782.0
50.0	0.708	1819.0
70.0	0.7109	1815.0
100.0	0.6991	1828.0



Gambar 5. Pengaruh Ukuran Populasi terhadap Akurasi dan Jumlah Fitur Terpilih

D. Maximum Number of Generation

Eksperimen ini mengevaluasi dampak jumlah generasi dalam algoritma PSO terhadap akurasi klasifikasi sentimen. Hasil ditampilkan dalam TABEL II, yang memperlihatkan akurasi dan jumlah fitur terpilih dari variasi generasi mulai 10 hingga 100. Akurasi tertinggi sebesar 0.7227 tercapai pada generasi ke-70, menjadikannya konfigurasi paling optimal dalam eksperimen ini. Sementara itu, jumlah fitur yang dipilih cenderung bervariasi, menunjukkan bahwa akurasi tidak selalu sejalan dengan jumlah fitur yang dipilih secara absolut.


Visualisasi tren eksperimen pada Gambar 6 memperkuat temuan tersebut. Garis biru menggambarkan fluktuasi akurasi, dengan puncak pada generasi ke-70,

sedangkan garis merah menunjukkan jumlah fitur terpilih. Meski akurasi tinggi juga terlihat pada generasi ke-30 dan ke-100, nilai tersebut tetap sedikit lebih rendah dibandingkan generasi ke-70.

Temuan ini konsisten dengan literatur seperti [29], yang menekankan pentingnya rentang 50–100 generasi untuk mencapai keseimbangan eksplorasi dan akurasi tanpa overfitting. Dengan demikian, pemilihan jumlah generasi yang tepat menjadi kunci dalam optimalisasi model berbasis PSO untuk klasifikasi sentimen.

TABEL II. EKSPERIMEN *MAXIMUM NUMBER OF GENERATION*

Generations	Accuracy	Selected Features
10	0.6962	1773
20	0.7109	1809
30	0.7168	1801
40	0.7109	1772
50	0.705	1794
60	0.7109	1836
70	0.7227	1783
80	0.7109	1762
90	0.7139	1756
100	0.7168	1825



Gambar 6. Pengaruh Jumlah Iterasi (*Generations*) terhadap Akurasi dan Seleksi Fitur

E. Inertia Weight


Eksperimen ketiga bertujuan mengevaluasi pengaruh bobot inersia terhadap kinerja optimasi PSO dalam seleksi fitur. Variasi nilai inersia diuji dari 1.0 hingga 2.0. Hasil pada TABEL III. Eksperimen *Inertia Weight* menunjukkan bahwa nilai inersia 1.2 menghasilkan akurasi tertinggi, yaitu 0.7050, dengan 1807 fitur terpilih. Ini menandakan adanya keseimbangan optimal antara kemampuan eksplorasi ruang solusi di awal dan eksploitasi solusi terbaik di fase akhir pencarian.

Visualisasi dalam Gambar 7 memperkuat temuan ini, dengan tren peningkatan akurasi hingga titik puncak pada inersia 1.2, kemudian menurun pada nilai inersia yang lebih tinggi. Fenomena ini konsisten dengan teori bahwa bobot inersia yang terlalu besar dapat menghambat konvergensi karena partikel terlalu lama menjelajah, sedangkan bobot terlalu kecil dapat menyebabkan konvergensi prematur ke solusi lokal. Strategi penyesuaian inersia dinamis seperti yang disarankan oleh [30] menjadi relevan dalam menjaga keseimbangan eksplorasi dan eksploitasi secara adaptif sepanjang proses iterasi. Oleh karena itu, pemilihan bobot

inersia yang tepat sangat krusial dalam meningkatkan akurasi klasifikasi berbasis PSO.

TABEL III. EKSPERIMEN *INERTIA WEIGHT*

Inertia	Accuracy	Selected Features
1.0	0.6962	1764
1.1	0.6991	1857
1.2	0.7050	1807
1.3	0.6991	1833
1.4	0.6962	1760
1.5	0.6962	1780
1.6	0.6844	1778
1.7	0.6814	1808
1.8	0.6873	1792
1.9	0.6932	1785
2.0	0.6844	1803

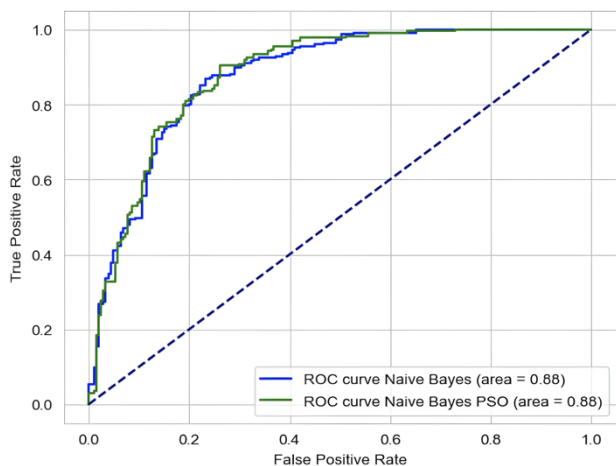


Gambar 7. Pengaruh *Inertia Weight* terhadap Akurasi & Seleksi Fitur

F. Perbandingan Naive Bayes vs. Naive Bayes + PSO


Evaluasi akhir dilakukan untuk membandingkan performa model *Naive Bayes* standar dengan model yang telah dioptimasi menggunakan *Particle Swarm Optimization* (PSO). Tiga metrik utama digunakan untuk menilai performa ROC Curve (Gambar 8), *confusion matrix* (Gambar 9), dan akurasi keseluruhan (Gambar 10).

Dari Gambar 8, kurva *Receiver Operating Characteristic* (ROC) menunjukkan bahwa kedua model memiliki *area under the curve* (AUC) yang sama, yaitu 0.88, mengindikasikan bahwa kemampuan klasifikasi keduanya dalam membedakan kelas positif dan negatif secara keseluruhan tetap stabil meskipun telah dilakukan optimasi. Namun, peningkatan nyata terlihat pada *confusion matrix*. Gambar 9 memperlihatkan bahwa model *Naive Bayes* + PSO mengurangi kesalahan klasifikasi terhadap kelas positif: dari 64 menjadi 59 kesalahan dan meningkatkan prediksi benar menjadi 168 dari sebelumnya 163.

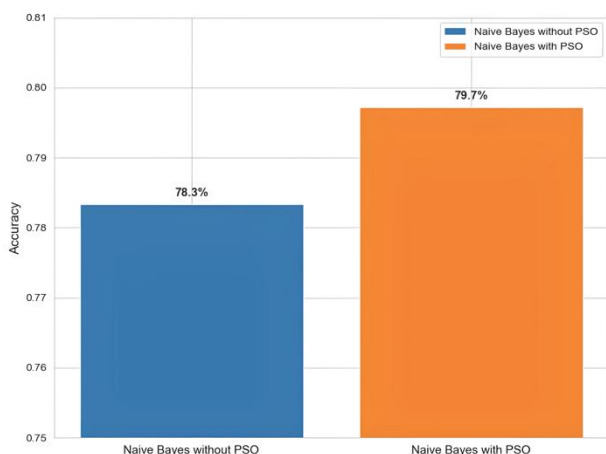


Gambar 8. ROC Curve Naive Bayes vs. Naive Bayes + PSO

Gambar 10 menunjukkan bahwa akurasi meningkat dari 78.3% menjadi 79.7%, yakni selisih 1.4%, sebagai hasil dari proses seleksi fitur yang lebih efisien melalui PSO. Peningkatan ini memperkuat temuan [27] dan [31] yang menegaskan bahwa PSO dapat meningkatkan performa model konvensional dalam tugas klasifikasi opini di media sosial.



Gambar 9. Confusion Matrix kedua model



Gambar 10. Perbandingan akurasi

IV. KESIMPULAN

Penelitian ini telah mengevaluasi pengaruh integrasi *Particle Swarm Optimization* (PSO) pada algoritma *Naive Bayes* (NB) dalam klasifikasi sentimen publik terhadap pembangunan Ibu Kota Nusantara (IKN). Hasil eksperimen menunjukkan bahwa optimasi parameter *smoothing*

menggunakan PSO menghasilkan peningkatan akurasi dari 78.3% (NB standar) menjadi 79.7% (NB+PSO), dengan konfigurasi populasi, iterasi, dan bobot inersia yang disesuaikan secara sistematis. Temuan ini menegaskan bahwa pendekatan *metaheuristik* seperti PSO dapat berkontribusi dalam memperbaiki performa model probabilistik yang sederhana tanpa meningkatkan kompleksitas arsitektur algoritma secara signifikan. Kontribusi utama dari studi ini adalah pada penerapan PSO sebagai metode optimasi parameter, bukan seleksi fitur eksplisit, dalam konteks klasifikasi teks pendek berbahasa Indonesia. Namun demikian, studi ini memiliki sejumlah keterbatasan teknis. Proses optimasi hanya mencakup satu parameter (α), tanpa mempertimbangkan konfigurasi multi-parameter atau struktur data fitur yang lebih kompleks. Selain itu, proses pelabelan sentimen yang mengandalkan terjemahan dan *TextBlob* cenderung tidak sepenuhnya menangkap nuansa semantik, idiom, dan sarkasme dalam bahasa asli. Keterbatasan tersebut menunjukkan bahwa performa model masih dapat ditingkatkan melalui pendekatan yang lebih adaptif terhadap struktur bahasa. Oleh karena itu, eksplorasi model *deep learning* seperti *BERT*, *LSTM*, atau *IndoBERT* menjadi penting untuk masa mendatang, terutama dalam menangani dependensi kontekstual dan representasi semantik yang lebih kaya. Rekomendasi ini tidak hanya berangkat dari tren metodologis, tetapi juga dari tantangan nyata yang dihadapi dalam studi ini terkait keterbatasan akurasi dan pemahaman linguistik.

REFERENSI

- [1] L. Agustino, M. D. Hikmawan, and J. Silas, "Is It Possible for Sustainability? The Case From the New Capital City of Indonesia," *Frontiers in Political Science*, vol. 6, 2024, doi: 10.3389/fpos.2024.1362337.
- [2] M. A. Kamal, "Prospects for the New Capital City Policy in Law and Economic Perspectives," *Substantive Justice International Journal of Law*, vol. 5, no. 1, p. 86, 2022, doi: 10.56087/substantivejustice.v5i1.205.
- [3] M. U. Ikfina, "Indonesia's National Capital Relocation Policy: An Analysis of Political Support in Parliament and the Public Responses on Twitter," *Journal of Governance and Public Policy*, vol. 11, no. 1, pp. 1–13, 2024, doi: 10.18196/jgpp.v11i1.17760.
- [4] R. Rachmawati *et al.*, "Achieving Sustainable Urban Development for Indonesia's New Capital City," *International Journal of Sustainable Development and Planning*, vol. 19, no. 2, 2024, doi: 10.18280/ijstdp.190204.
- [5] A. Nuryadin, L. Subagiyo, N. F. Sulaeman, S. Dinurrohmah, and P. S. Rahmawati, "Investigation of Students' Pro-Environmental Behavior Around Indonesia's New Capital City," *International Journal of Evaluation and Research in Education (Ijere)*, vol. 12, no. 2, p. 594, 2023, doi: 10.11591/ijere.v12i2.24423.
- [6] S. I. F. Asfianur, S. Suswanta, R. Al-Hamdi, and Z. Qodir, "Discourse on Moving the New Capital City in East Kalimantan Province a Political Economy Perspective," *Masyarakat Kebudayaan Dan Politik*, vol. 36, no. 3, pp. 379–393, 2023, doi: 10.20473/mkp.v36i32023.379-393.

- [7] D. Kadewardana and A. Cahyadi, "Public Opinion Analysis on Social Media About the Establishment of Indonesia's New Capital City," *Islamic Communication Journal*, vol. 8, no. 2, pp. 229–250, 2023, doi: 10.21580/icj.2023.8.2.18283.
- [8] A. K. Darmawan, M. W. A. Wajieh, M. B. Setyawan, T. Yandi, and H. Hoiriyah, "Hoax News Analysis for the Indonesian National Capital Relocation Public Policy With the Support Vector Machine and Random Forest Algorithms," *Journal of Information Systems and Informatics*, vol. 5, no. 1, pp. 150–173, 2023, doi: 10.51519/journalisi.v5i1.438.
- [9] H. Akeda and M. A. Muslim, "Narrative Policy Analysis: What Is Behind the Movement of Capital City of Indonesia," *Journal of Education Humaniora and Social Sciences (Jehss)*, vol. 6, no. 2, pp. 664–676, 2023, doi: 10.34007/jehss.v6i2.1930.
- [10] H. Herdiawanto, "The Position of the Nusantara Capital City From a National Security Perspective," *Masyarakat Kebudayaan Dan Politik*, vol. 36, no. 4, pp. 545–558, 2023, doi: 10.20473/mkp.v36i42023.545-558.
- [11] M. H. Tsai and Y. Wang, "Analyzing Twitter Data to Evaluate People's Attitudes Towards Public Health Policies and Events in the Era of COVID-19," *International Journal of Environmental Research and Public Health*, vol. 18, no. 12, p. 6272, 2021, doi: 10.3390/ijerph18126272.
- [12] Y. A. Mustofa and I. S. K. Idris, "Ensemble Approach to Sentiment Analysis of Google Play Store App Reviews," *Jambura Journal of Electrical and Electronics Engineering*, vol. 6, no. 2, pp. 181–188, 2024, doi: 10.37905/jjee.v6i2.25184.
- [13] W. B. Zulfikar, A. R. Atmadja, and S. F. Pratama, "Sentiment Analysis on Social Media Against Public Policy Using Multinomial Naive Bayes," *Scientific Journal of Informatics*, vol. 10, no. 1, pp. 25–34, 2023, doi: 10.15294/sji.v10i1.39952.
- [14] N. A. O. Saputri, M. Misinem, and K. Zuhri, "Analysis of Sentiment Based on Opinions From the 2019 Presidential Election," *Jods*, vol. 2024, no. 1, 2024, doi: 10.61453/jods.v2024no25.
- [15] N. Z. B. Jannah and K. Kusnawi, "Comparison of Naïve Bayes and SVM in Sentiment Analysis of Product Reviews on Marketplaces," *Sinkron*, vol. 8, no. 2, pp. 727–733, 2024, doi: 10.33395/sinkron.v8i2.13559.
- [16] M. A. Ayu and A. H. Muhendra, "Preprocessing of Slang Words for Sentiment Analysis on Public Perceptions in Twitter," 2024, doi: 10.5772/intechopen.113725.
- [17] W. Ashiq *et al.*, "Roman Urdu Hate Speech Detection Using Hybrid Machine Learning Models and Hyperparameter Optimization," *Scientific Reports*, vol. 14, no. 1, 2024, doi: 10.1038/s41598-024-79106-7.
- [18] M. M. Dakwah, A. A. Firdaus, F. Furizal, and R. Faresta, "Sentiment Analysis on Marketplace in Indonesia Using Support Vector Machine and Naïve Bayes Method," *Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika*, vol. 10, no. 1, p. 39, 2024, doi: 10.26555/jiteki.v10i1.28070.
- [19] T. N. Wijaya, R. Indriati, and M. N. Muzaki, "Analisis Sentimen Opini Publik Tentang Undang-Undang Cipta Kerja Pada Twitter," *Jambura Journal of Electrical and Electronics Engineering*, vol. 3, no. 2, pp. 78–83, 2021.
- [20] A. D. Anggraeni, M. Farhansyah, M. R. P. Hermawan, G. W. Wicaksono, and C. S. K. Aditya, "Comparison of Classification Methods on Twitter Sentiment Analysis of PDAM Tugu Tirta Kota Malang," *Juita Jurnal Informatika*, vol. 11, no. 1, p. 67, 2023, doi: 10.30595/juita.v11i1.15485.
- [21] I. S. K. Idris, Y. A. Mustofa, and I. Salihi, "Analisis Sentimen Terhadap Penggunaan Aplikasi Shopee Menggunakan Algoritma Support Vector Machine (SVM)," *Jambura Journal of Electrical and Electronics Engineering*, vol. 5, no. 1, pp. 32–35, 2023, doi: 10.37905/jjee.v5i1.16830.
- [22] R. Setiabudi, N. M. S. Iswari, and A. Rusli, "Enhancing Text Classification Performance by Preprocessing Misspelled Words in Indonesian Language," *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 19, no. 4, p. 1234, 2021, doi: 10.12928/telkomnika.v19i4.20369.
- [23] R. N. Aufa, S. S. Prasetiyowati, and Y. Sibaroni, "The Effect of Feature Weighting on Sentiment Analysis TikTok Application Using the RNN Classification," *Building of Informatics Technology and Science (Bits)*, vol. 5, no. 1, 2023, doi: 10.47065/bits.v5i1.3597.
- [24] A. R. Isnain, N. S. Marga, and D. Alita, "Sentiment Analysis of Government Policy on Corona Case Using Naive Bayes Algorithm," *Ijccs (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 15, no. 1, p. 55, 2021, doi: 10.22146/ijccs.60718.
- [25] R. Hakiki, A. Pambudi, and Asriyanik, "Classification of Public Sentiment Toward 2024 Presidential Candidates on Social Media Platform X Using Naïve Bayes Algorithm," *J. Of Artif. Intell. And Eng. Appl.*, vol. 3, no. 2, pp. 551–556, 2024, doi: 10.59934/jaiea.v3i2.422.
- [26] Y. Affandi and E. Sugiharti, "Sentiment Analysis of Student on Online Lectured During Covid-19 Pandemic Using K-Means and Naïve Bayes Classifier," *Journal of Advances in Information Systems and Technology*, vol. 5, no. 1, pp. 38–49, 2023, doi: 10.15294/jaist.v5i1.64903.
- [27] S. Supangat, M. Z. Saringat, and M. Y. F. Rochman, "Predicting Handling Covid-19 Opinion Using Naive Bayes and TF-IDF for Polarity Detection," *Matrik Jurnal Manajemen Teknik Informatika Dan Rekayasa Komputer*, vol. 22, no. 2, pp. 173–184, 2023, doi: 10.30812/matrik.v22i2.2227.
- [28] A. R. Lubis, M. K. M. Nasution, O. S. Sitompul, and E. M. Zamzami, "The Feature Extraction for Classifying Words on Social Media With the Naïve Bayes Algorithm," *Iaes International Journal of Artificial Intelligence (Ij-Ai)*, vol. 11, no. 3, p. 1041, 2022, doi: 10.11591/ijai.v11.i3.pp1041-1048.
- [29] B. Chanakot and K. Phoksawat, "Analysis of Consumer Sentiments Towards Online Shopping Using Context-Free Grammar and Deep Learning," *Revue D Intelligence Artificielle*, vol. 38, no. 1, pp. 193–199, 2024, doi: 10.18280/ria.380119.
- [30] J. A. Widians, R. Wardoyo, and S. Hartati, "Feature Selection Based on Chi-Square and Ant Colony Optimization for Multi-Label Classification,"

International Journal of Electrical and Computer Engineering (Ijece), vol. 14, no. 3, p. 3303, 2024, doi: 10.11591/ijece.v14i3.pp3303-3312.

[31] W. Dirgantara, F. I. Maulana, Subairi, and R. Arifuddin, "The Performance of Machine Learning Model

Bernoulli Naïve Bayes, Support Vector Machine, and Logistic Regression on COVID-19 in Indonesia Using Sentiment Analysis," *Techné Jurnal Ilmiah Elektroteknika*, vol. 23, no. 1, pp. 153–162, 2024, doi: 10.31358/techne.v23i1.446.