



Model Deteksi Berita Hoaks Bahasa Indonesia Menggunakan Multinomial Naïve Bayes dan AdaBoost Classifier

Haniifaa Hafiizh, Safitri Juanita*

Fakultas Teknologi Informasi, Program Studi Sistem Informasi, Universitas Budi Luhur, Jakarta, Indonesia

Email: ¹2212501098@student.budiluhur.ac.id, ^{2,*}safitri.juanita@budiluhur.ac.id

Email Penulis Korespondensi: safitri.juanita@budiluhur.ac.id

Abstrak—Perkembangan internet yang semakin pesat menyebabkan arus informasi pada berbagai platform digital tersebar secara masif dan sulit dikendalikan, sehingga berita hoaks berpotensi menjangkau banyak pengguna dan memengaruhi opini publik dalam waktu singkat. Kondisi ini menuntut adanya sistem deteksi otomatis yang andal. Namun, metode yang tersedia saat ini masih menghadapi keterbatasan dalam hal akurasi, kestabilan hasil, serta ketergantungan pada proses verifikasi manual. Oleh karena itu, penelitian ini bertujuan untuk membandingkan dan menganalisis kinerja dua algoritma klasifikasi dalam mendeteksi berita hoaks berbahasa Indonesia secara akurat dan efektif. Penelitian ini mengikuti tahapan CRISP-DM, yang diawali dengan pengumpulan data berupa berita hoaks dan non-hoaks dari turnbackhoax.id dan detik.com hingga diperoleh 2.281 sampel. Tahap pemahaman data dilakukan melalui analisis karakteristik dataset dan evaluasi kualitas data. Pada tahap persiapan data, elemen teks yang secara eksplisit merujuk pada label hoaks dihilangkan, kemudian dilakukan ekstraksi fitur menggunakan Term Frequency–Inverse Document Frequency (TF-IDF). Selanjutnya, dataset dilatih dan diuji menggunakan skema pembagian data 70:30, 80:20, dan 90:10, dengan menerapkan algoritma Multinomial Naïve Bayes dan AdaBoost Classifier. Evaluasi performa dilakukan menggunakan confusion matrix. Hasil penelitian menunjukkan bahwa AdaBoost memberikan performa paling unggul dengan akurasi sebesar 0.9879 (98.79%), lebih tinggi dibandingkan Multinomial Naïve Bayes yang memperoleh akurasi 0.9712 (97.12%). Kinerja AdaBoost juga menunjukkan hasil yang stabil pada berbagai skenario pengujian, sehingga dinilai lebih tepat digunakan sebagai model deteksi otomatis berita hoaks pada dataset yang digunakan.

Kata Kunci: AdaBoost; Berita Hoaks; CRISP-DM; Klasifikasi Teks; TF-IDF

Abstract—The rapid growth of the internet has led to the massive and uncontrolled dissemination of information across various digital platforms, allowing hoax news to reach a wide audience and influence public opinion in a short period of time. This condition highlights the need for a reliable automated detection system. However, existing methods still face limitations in terms of accuracy, result stability, and reliance on manual verification processes. Therefore, this study aims to compare and analyze the performance of two classification algorithms in detecting Indonesian-language hoax news accurately and effectively. This study follows the CRISP-DM framework, beginning with the collection of hoax and non-hoax news articles from turnbackhoax.id and detik.com, resulting in 2,281 samples. The data understanding stage involves analyzing dataset characteristics and evaluating data quality. During data preparation, text elements that explicitly indicate hoax labels are removed, followed by feature extraction using Term Frequency–Inverse Document Frequency (TF-IDF). The dataset is then trained and tested using data split ratios of 70:30, 80:20, and 90:10 by applying Multinomial Naïve Bayes and AdaBoost Classifier algorithms. Model performance is evaluated using a confusion matrix. The results show that AdaBoost achieves superior performance, with an accuracy of 0.9879 (98.79%), outperforming Multinomial Naïve Bayes, which attains an accuracy of 0.9712 (97.12%). The performance of AdaBoost is also consistent across different evaluation scenarios, indicating that it is more suitable as an automated hoax news detection model for the dataset used in this study.

Keywords: AdaBoost; Hoax News; CRISP-DM; Text Classification; TF-IDF

1. PENDAHULUAN

Perkembangan internet memiliki peran yang sangat signifikan dalam mempercepat penyebaran informasi melalui berbagai platform digital [1]. Suatu peristiwa yang baru terjadi dapat dengan mudah tersebar secara luas, bahkan mencapai skala global dalam hitungan menit [2]. Namun, tingginya kecepatan dan volume arus informasi tersebut tidak selalu diiringi dengan proses verifikasi yang memadai, sehingga memicu meningkatnya penyebaran berita dari sumber yang tidak terverifikasi atau tidak terpercaya [3]. Fenomena ini berkontribusi pada maraknya berita palsu atau hoaks di ruang digital. Berita hoaks didefinisikan sebagai informasi yang secara sengaja disebar dengan tujuan menyesatkan atau menipu pembaca [4],[5]. Informasi yang disajikan dalam berita hoaks sering kali mengalami distorsi, dilebih-lebihkan, atau bahkan sepenuhnya tidak sesuai dengan fakta [6].

Saat ini, Undang-Undang No. 19 Tahun 2016 tentang Informasi dan Transaksi Elektronik (ITE) mengatur hal tersebut, seseorang atau individu tertentu yang melanggarnya akan dijatuhi sanksi sesuai dengan peraturan yang berlaku [7]. Dampak penyebaran hoaks tidak hanya terbatas pada kesalahpahaman informasi, tetapi juga berpotensi memengaruhi opini publik, stabilitas sosial, serta pengambilan keputusan masyarakat. Oleh karena itu, upaya untuk mengatasi penyebaran berita hoaks, khususnya di media digital dan media sosial, menjadi semakin mendesak [8]. Permasalahan utama dalam deteksi berita hoaks saat ini terletak pada kinerja sistem yang belum optimal, terutama dari sisi akurasi dan kestabilan performa.

Selain itu, proses verifikasi berita hoaks dan berita bukan hoaks (non-hoaks) masih banyak dilakukan secara manual, sehingga memerlukan waktu yang relatif lama dan tidak efisien ketika dihadapkan pada volume data yang besar. Kondisi ini semakin rumit ketika digunakan pada bahasa Indonesia yang memiliki fitur yang berbeda, seperti penggunaan singkatan, slang, ejaan yang tidak standar, dan struktur kalimat yang fleksibel, yang sering kali tidak terakomodasi dengan baik oleh model analisis teks atau sentimen yang umum digunakan [9]. Oleh karena itu, perlunya pengembangan sistem deteksi otomatis berbasis pembelajaran mesin yang mampu memberikan hasil klasifikasi yang akurat, konsisten, dan



efisien. Sejumlah penelitian sebelumnya telah mengkaji klasifikasi berita hoaks menggunakan berbagai pendekatan dan algoritma dengan hasil yang beragam. Penelitian oleh Taufik dan Henny (2025) [3] menunjukkan efektivitas pendekatan *Natural Language Processing* (NLP) dalam deteksi hoaks menggunakan algoritma *Naïve Bayes* dan *Random Forest*, dengan akurasi masing-masing sebesar 92,5% dan 95,6%. Ayuni et al. (2021) [10] menerapkan metode *Vector Space Model* untuk klasifikasi berita hoaks dan non-hoaks, dengan tingkat akurasi sebesar 83% pada skenario K-6. Fathillah et al. (2023) [11] menggunakan *Multinomial Naïve Bayes* dan *Gaussian Naïve Bayes*, dengan hasil akurasi tertinggi sebesar 96% pada *Multinomial Naïve Bayes*.

Sementara itu, Ropikoh et al. (2021) [12] menerapkan algoritma *Support Vector Machine* (SVM) dalam mendeteksi hoaks COVID-19 dan memperoleh akurasi tertinggi sebesar 97,06% pada *kernel linear* dengan skenario pembagian data 80:20. Kurnia et al. (2024) [13] membandingkan algoritma *Naïve Bayes* memperoleh akurasi 90,71% sementara CNN mencapai 80,86% pada berita hoaks politik Indonesia menggunakan dataset Turnbackhoax.id. Penelitian lain oleh Harahap (2021) [14] menunjukkan bahwa *Multinomial Naïve Bayes* memberikan performa lebih baik dibandingkan *Naïve Bayes* standar dalam klasifikasi hoaks kesehatan.

Meskipun penelitian-penelitian tersebut menunjukkan bahwa berbagai algoritma mampu mencapai tingkat akurasi yang tinggi, sebagian besar studi masih berfokus pada penggunaan algoritma tunggal tanpa membandingkannya dengan algoritma lain, atau melakukan perbandingan terbatas tanpa menekankan aspek kestabilan performa pada berbagai skenario pengujian. Keberhasilan dalam sebuah *preprocessing* juga sangat penting seperti menerapkan *missing value* dalam ekstraksi fitur, pengoptimalan pengklasifikasi hingga prapemrosesan data [15]. Selain itu, pemanfaatan kerangka kerja CRISP-DM secara sistematis dalam deteksi hoaks masih relatif terbatas. Hal inilah yang menjadi celah penelitian (*research gap*) dalam studi ini. Berdasarkan gap tersebut, penelitian ini mengusulkan pendekatan deteksi berita hoaks berbahasa Indonesia dengan membandingkan dua algoritma, yaitu *Multinomial Naïve Bayes* dan *AdaBoost (Adaptive Boosting)*, dalam kerangka kerja CRISP-DM. Kedua algoritma tersebut dievaluasi dan dibandingkan untuk menilai efektivitas dan kestabilan kinerjanya dalam mendeteksi berita hoaks melalui berbagai skenario pengujian. Evaluasi performa dilakukan menggunakan *confusion matrix* yang mencakup metrik akurasi, *precision*, *recall*, dan *F1-score*, untuk mengukur kemampuan generalisasi model.

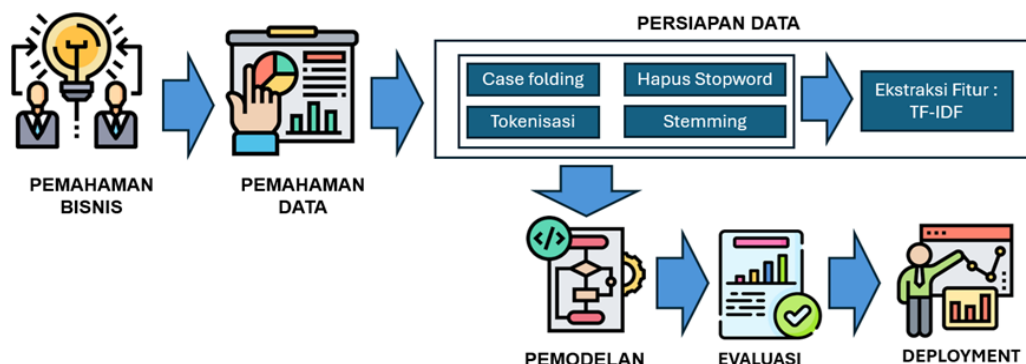
Pemilihan *Multinomial Naïve Bayes* dan *AdaBoost* dalam penelitian ini didasarkan pada perbedaan karakteristik keduanya dalam klasifikasi teks. *Multinomial Naïve Bayes* digunakan karena memanfaatkan distribusi *multinomial* untuk menghitung probabilitas kelas berdasarkan frekuensi kemunculan kata, sehingga menjadi model pembandingan yang sederhana dan efisien [16]. Sementara itu, *AdaBoost* merupakan algoritma *ensemble* yang meningkatkan kinerja klasifikasi dengan memperbaiki kesalahan prediksi secara iteratif melalui penggabungan *weak learners* [17]. Perbandingan kedua algoritma dilakukan untuk mengevaluasi perbedaan performa antara pendekatan klasifikasi yang sederhana dan pendekatan *ensemble*, serta untuk menentukan model yang paling efisien dan stabil dalam mendeteksi berita hoaks berbahasa Indonesia.

Tujuan utama penelitian ini adalah untuk menganalisis dan menentukan algoritma yang paling efektif dan akurat dengan membandingkan 2 algoritma yaitu *Multinomial Naïve Bayes* dan *AdaBoost* dalam mendeteksi berita hoaks berbahasa Indonesia. Penelitian ini juga bertujuan untuk menghasilkan model deteksi otomatis yang memiliki tingkat akurasi tinggi dan performa yang stabil pada berbagai skenario pengujian. Diharapkan, hasil penelitian ini tidak hanya mampu mempercepat proses verifikasi berita yang sebelumnya memakan waktu lama, tetapi juga memberikan kontribusi nyata dalam pengembangan sistem deteksi berita hoaks yang lebih andal dan aplikatif di Indonesia.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Pada Gambar 1 merupakan tahapan penelitian yang terdiri dari beberapa proses penelitian yang dilakukan.



Gambar 1. Tahapan Penelitian

Tahapan penelitian seperti Gambar 1 menggunakan metode tahapan *Cross Industry Standard Process for Data Mining (CRISP-DM)* [18], adapun penjelasan pada tiap tahapan sebagai berikut:



a. Pemahaman Bisnis.

Pada tahap ini dilakukan untuk menentukan permasalahan yang diangkat yaitu membandingkan performa *Multinomial Naïve Bayes* dan *AdaBoost* pada berita Indonesia, dengan tujuan untuk membangun dan mengevaluasi model klasifikasi hoaks yang akurat dan stabil. Sehingga mampu menangani ketidakseimbangan kelas.

b. Pemahaman Data.

Pada tahap ini dilakukan pengumpulan dan analisis dataset yang berisi teks berita hoaks dan non-hoaks berbahasa Indonesia yang dipublikasikan pada periode Januari hingga Oktober 2025. Dataset yang digunakan memiliki beberapa atribut, yaitu judul berita, tanggal publikasi, tautan berita, dan isi berita. Data berita hoaks diperoleh dari situs turnbackhoax.id sebanyak 1.155 artikel, sedangkan data berita non-hoaks dikumpulkan dari detik.com sebanyak 5.640 artikel. Pada Tabel 1 menampilkan sampel teks berita hoaks dan bukan hoaks (non-hoaks).

Tabel 1. Sampel Teks Berita Hoaks dan Berita Bukan Hoaks

Teks Berita Hoaks	Teks Berita Bukan Hoaks (non-hoaks)
PT Plaza Indonesia Realty Tbk disebut terkait penyebaran informasi menyesatkan mengenai kepemilikan Hotel Grand Hyatt.	Wakil Ketua MPR RI Lestari Moerdijat menegaskan pentingnya perlindungan tenaga medis dalam sistem pendidikan dokter spesialis.

c. Persiapan Data.

Pada tahap ini, dilakukan penyiapan dan pra-pemrosesan data untuk pemodelan. Berikut adalah tahapan-tahapan dari penyiapan data dan pra-pemrosesan data:

1. Penyeimbangan jumlah data hoaks dan non-hoaks dilakukan secara manual menggunakan fitur filter pada Microsoft Excel. Proses ini bertujuan untuk memperoleh komposisi data yang lebih seimbang serta meningkatkan kualitas dataset yang digunakan dalam proses pemodelan. Tahapan penyeimbangan data dalam penelitian ini dilakukan melalui proses seleksi dan penyaringan terhadap data hoaks dan non-hoaks agar diperoleh distribusi kelas yang lebih seimbang dan representatif. Data non-hoaks diseleksi dengan menetapkan kriteria minimal 370 kata pada isi berita, sehingga artikel yang tidak memenuhi batasan tersebut dikeluarkan dari dataset. Sementara itu, data hoaks difilter berdasarkan judul berita yang mengandung kata kunci “salah” dan “penipuan” sebagai indikator utama konten yang menyesatkan. Berdasarkan proses ini, jumlah data hoaks yang semula sebanyak 1.155 artikel berkurang menjadi 1.134 artikel, sedangkan data non-hoaks yang awalnya berjumlah 5.640 artikel menyusut menjadi 1.147 artikel, sehingga distribusi kedua kelas menjadi lebih seimbang untuk keperluan pelatihan model.
2. Tahap pelabelan dilakukan secara manual berdasarkan sumber data. Artikel berita yang diperoleh dari situs turnbackhoax.id diberi label hoaks dengan nilai 1, sedangkan artikel berita yang bersumber dari detik.com diberi label non-hoaks dengan nilai 0. Proses pelabelan ini bertujuan untuk membedakan secara jelas antara kedua kelas data sebelum dilakukan pemodelan. Contoh sampel dataset yang telah diberi label disajikan pada Tabel 2.

Tabel 2. Sampel Teks Labeling

Label	Teks
1	PT Plaza Indonesia Realty Tbk disebut terkait penyebaran informasi menyesatkan mengenai kepemilikan Hotel Grand Hyatt.
0	Wakil Ketua MPR RI Lestari Moerdijat menegaskan pentingnya perlindungan tenaga medis dalam sistem pendidikan dokter spesialis.

3. Pra-pemrosesan teks dilakukan untuk mengubah data teks yang tidak terstruktur menjadi format yang lebih bersih, terdiri dari lima tahapan utama. Dimulai dari tahapan prapemrosesan teks dalam penelitian ini dimulai dengan proses *cleaning* untuk menghapus elemen yang tidak diperlukan seperti tautan URL, angka, simbol, dan tanda baca agar teks menjadi lebih bersih dan siap dianalisis. Selanjutnya dilakukan *case folding* dengan menyeragamkan seluruh huruf menjadi huruf kecil guna menghindari perbedaan makna akibat variasi kapitalisasi. Proses berikutnya adalah *tokenizing*, yaitu memecah kalimat atau paragraf menjadi unit kata individual sehingga memudahkan analisis lebih lanjut. Setelah itu, dilakukan penghapusan *stopword* menggunakan Sastrawi, kamus tambahan, dan daftar *stopword* khusus yang disusun dalam penelitian ini untuk menghilangkan kata-kata yang tidak memiliki makna penting atau yang secara eksplisit dapat merujuk pada label kelas. Untuk label hoaks, *stopword* tambahan mencakup berbagai istilah yang berkaitan dengan verifikasi, klarifikasi, misinformasi, disinformasi, serta kata-kata yang sering muncul dalam konteks pemeriksaan fakta dan penyebaran hoaks, sehingga model tidak belajar dari petunjuk eksplisit terhadap kelas. Sementara itu, untuk label non-hoaks, *stopword* tambahan meliputi istilah seperti tautan, cuitan, konten, unggahan, arsip, pemeriksaan, situs, blog, redaksi, editor, dan wawancara yang sering muncul pada berita sah namun tidak relevan untuk klasifikasi. Tahap terakhir adalah *stemming*, yaitu mengubah kata berimbuhan menjadi bentuk dasarnya agar variasi morfologis tidak memengaruhi representasi fitur dan meningkatkan konsistensi dalam proses pemodelan. Pada Tabel 3 menampilkan sampel dataset sebelum dan sesudah prapemrosesan teks.



Tabel 3. Sampel Teks Sesudah Prapemrosesan data

Sebelum Prapemrosesan data	Sesudah Prapemrosesan data
PT Plaza Indonesia Realty Tbk disebut terkait penyebaran informasi menyesatkan mengenai kepemilikan Hotel Grand Hyatt.	pt plaza indonesia realty tbk sebut kait penyebaran informasi sesat milik hotel grand hyatt

4. Pembagian data latih dan data uji dilakukan untuk mengevaluasi kinerja model serta menentukan skema pembagian data yang menghasilkan performa terbaik. Dalam penelitian ini, digunakan dua metode evaluasi, yaitu metode *split* dengan beberapa skema pembagian data, yaitu 70:30, 80:20, dan 90:10, untuk membandingkan kinerja model pada proporsi data yang berbeda.

5. Ekstraksi fitur *TF-IDF*.

TF (*Term Frequency*) untuk mengukur frekuensi kemunculan kata dan *IDF* (*Inverse Document Frequency*) *inverse document frequency* mengukur kelangkaan kata pada dokumen dengan menggunakan persamaan (1) dan (2) [19]. Selanjutnya divisualisasikan dengan wordcloud, sehingga teks siap digunakan dalam pemodelan.

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

$$IDF(t) = \log \frac{N}{df(t)} \quad (2)$$

Dalam konteks perhitungan, N merepresentasikan total jumlah dokumen dalam korpus, sedangkan df(t) menunjukkan jumlah dokumen yang mengandung term t.

- d. Pemodelan.

Pada tahap pemodelan, dataset yang telah melalui pra-pemrosesan digunakan untuk membangun dua model klasifikasi, yaitu *Multinomial Naïve Bayes* dan *AdaBoost Classifier*. Model *Multinomial Naïve Bayes* diterapkan menggunakan kelas *MultinomialNB* pada *library scikit-learn* karena kesesuaiannya dalam menangani data teks berdasarkan distribusi frekuensi kata. Sedangkan model *AdaBoost* diterapkan melalui kelas *AdaBoostClassifier* dengan menggunakan *base estimator* bawaan, yaitu *Decision Tree (Stump)* seperti yang disediakan pada *scikit-learn* tanpa dilakukan perubahan pada konfigurasi dasar.

- e. Evaluasi.

Penilaian dalam penelitian ini dilakukan dengan tujuan untuk mengidentifikasi performa model menggunakan *confusion matrix* untuk menilai kemampuan model dalam membedakan kelas positif dan negatif secara *independen* dari *threshold* [20]. *Confusion matrix* adalah suatu struktur tabel yang memberikan perbandingan antara hasil klasifikasi yang diperoleh dari sistem (prediksi) dengan hasil klasifikasi yang sebenarnya, tabel pada *confusion matrix* memvisualisasikan jumlah data uji yang sudah diklasifikasi dengan benar dan jumlah data uji yang salah di klasifikasikan [21]. Perhitungan *confusion matrix* sebagai berikut [22].

$$\text{Akurasi} = \left(\frac{TP+TN}{TP+FP+FN+TN} \right) \times 100 \quad (3)$$

$$\text{Presisi} = \left(\frac{TP}{TP+FP} \right) \times 100 \quad (4)$$

$$\text{Recall} = \left(\frac{TP}{TP+FN} \right) \times 100 \quad (5)$$

$$F\text{-Measure} = 2 \times \left(\frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \times 100 \quad (6)$$

Dalam evaluasi kinerja klasifikasi, TP merepresentasikan jumlah prediksi positif yang benar, FP menunjukkan prediksi positif yang salah, TN menyatakan prediksi negatif yang benar, dan FN menggambarkan prediksi negatif yang salah.

- f. *Deployment*.

Tahap ini, memiliki fokus pada penggunaan hasil pemodelan yang telah dievaluasi. Model yang memiliki kinerja terbaik disarankan untuk dimasukkan ke dalam sistem pendukung keputusan.

3. HASIL DAN PEMBAHASAN

3.1 Visualisasi Distribusi Kata pada Dataset

Visualisasi kumpulan kata dilakukan menggunakan metode *word cloud* untuk menggambarkan frekuensi kemunculan kata pada isi berita hoaks dan non-hoaks. Visualisasi ini bertujuan untuk memberikan gambaran awal mengenai pola kata yang dominan pada masing-masing kelas data. Gambar 2 menampilkan hasil *word cloud* untuk berita hoaks, sedangkan Gambar 3 menunjukkan *word cloud* untuk berita non-hoaks. Perbedaan distribusi kata pada kedua visualisasi tersebut dapat membantu memahami karakteristik linguistik yang membedakan berita hoaks dan non-hoaks, serta menjadi dasar dalam proses ekstraksi fitur dan pemodelan klasifikasi selanjutnya

**Tabel 6.** Performa Multinomial Naïve Bayes dalam Mengklasifikasikan Berita Hoaks dan non-Hoaks

Latih-uji	Kelas	Precision	Recall	F1-score	Akurasi
70:30	Non-Hoaks (0)	0.9626	0.9738	0.9682	0.9668
	Hoaks (1)	0.9733	0.9619	0.9676	
80:20	Non-Hoaks (0)	0.9620	0.9913	0.9764	0.9666
	Hoaks (1)	0.9909	0.9604	0.9754	
90:10	Non-Hoaks (0)	0.9580	0.9913	0.9744	0.9712
	Hoaks (1)	0.9909	0.9561	0.9732	

3.4.2 Evaluasi Performa Model AdaBoost

Berdasarkan hasil evaluasi pada Tabel 7, algoritma AdaBoost Classifier menunjukkan performa yang sangat tinggi dan konsisten dalam mengklasifikasikan berita hoaks dan non-hoaks pada seluruh skema pembagian data, yaitu 70:30, 80:20, dan 90:10. Nilai akurasi tertinggi diperoleh pada skema 80:20 dengan nilai sebesar 0.9879, yang menunjukkan bahwa proporsi data latih dan data uji pada skema ini mampu menghasilkan kinerja klasifikasi yang paling optimal secara keseluruhan.

Tabel 7. Hasil Evaluasi Performa AdaBoost Classifier pada Klasifikasi Berita Hoaks dan Non-Hoaks

Latih-uji	Kelas	Precision	Recall	F1-score	Akurasi
70:30	Non-Hoaks (0)	0.9913	0.9942	0.9927	0.9875
	Hoaks (1)	0.9941	0.9912	0.9927	
80:20	Non-Hoaks (0)	0.9870	0.9913	0.9892	0.9879
	Hoaks (1)	0.9912	0.9868	0.9890	
90:10	Non-Hoaks (0)	1.0000	0.9913	0.9956	0.9859
	Hoaks (1)	0.9913	1.0000	0.9956	

Berdasarkan Tabel 7, dari sisi *precision*, kelas non-hoaks mencapai nilai tertinggi pada skema 90:10, yaitu sebesar 1.0000, yang mengindikasikan bahwa seluruh berita yang diprediksi sebagai non-hoaks pada skema tersebut benar-benar merupakan berita non-hoaks. Sementara itu, kelas hoaks memperoleh nilai *precision* tertinggi pada skema 70:30, yaitu sebesar 0.9941, yang menunjukkan tingkat ketepatan prediksi hoaks yang sangat tinggi. Untuk metrik *recall*, kelas non-hoaks memperoleh nilai tertinggi pada skema 70:30 dengan nilai sebesar 0.9942, yang menunjukkan bahwa hampir seluruh berita non-hoaks berhasil dikenali dengan benar.

Sebaliknya, kelas hoaks mencapai nilai *recall* tertinggi pada skema 90:10, yaitu sebesar 1.0000, yang berarti seluruh berita hoaks pada data uji berhasil terdeteksi tanpa adanya *false negative*. Pada metrik *F1-score*, performa terbaik untuk kedua kelas, baik non-hoaks maupun hoaks, diperoleh pada skema 90:10 dengan nilai sebesar 0.9956. Hal ini menunjukkan keseimbangan yang sangat baik antara *precision* dan *recall* pada skema tersebut. Secara keseluruhan, skema 80:20 memberikan performa terbaik dari sisi akurasi global, sedangkan skema 90:10 menunjukkan keunggulan pada metrik klasifikasi per kelas, khususnya dalam hal *precision*, *recall*, dan *F1-score*. Hasil ini mengindikasikan bahwa peningkatan proporsi data latih memberikan dampak positif terhadap kemampuan AdaBoost dalam mengenali karakteristik berita hoaks dan non-hoaks secara lebih presisi dan stabil.

3.4.3 Perbandingan Performa Tertinggi Multinomial Naïve Bayes dan AdaBoost

Berdasarkan Tabel 8, algoritma AdaBoost secara konsisten menghasilkan nilai *precision* dan *recall* yang lebih tinggi dibandingkan Multinomial Naïve Bayes pada kedua kelas. Untuk kelas non-hoaks, nilai *precision* tertinggi AdaBoost mencapai 1.0000, sedangkan Multinomial Naïve Bayes hanya mencapai 0.9626. Pada kelas hoaks, AdaBoost juga memperoleh nilai *precision* lebih tinggi, yaitu 0.9941, dibandingkan 0.9909 pada Multinomial Naïve Bayes. Dari sisi *recall*, AdaBoost menunjukkan keunggulan yang lebih jelas, khususnya pada kelas hoaks dengan nilai sempurna 1.0000, sementara Multinomial Naïve Bayes (MNB) hanya mencapai 0.9619. Hal ini menunjukkan bahwa AdaBoost lebih efektif dalam mendeteksi seluruh berita hoaks tanpa melewatkan kasus yang sebenarnya hoaks.

Selanjutnya, berdasarkan Tabel 9, nilai *F1-score* tertinggi untuk kedua kelas juga diperoleh oleh AdaBoost, yaitu sebesar 0.9956, sedangkan Multinomial Naïve Bayes hanya mencapai sekitar 0.9764 untuk non-hoaks dan 0.9754 untuk hoaks. Secara keseluruhan, hasil ini menegaskan bahwa AdaBoost memiliki performa yang lebih unggul dan seimbang dibandingkan Multinomial Naïve Bayes dalam klasifikasi berita hoaks berbahasa Indonesia.

Tabel 8. Perbandingan Nilai Precision dan Recall Tertinggi antara Multinomial Naïve Bayes dan AdaBoost

Label	Precision				Recall			
	skema	MNB	skema	AdaBoost	skema	MNB	skema	AdaBoost
Non-hoaks	70:30	0.9626	90:10	1.0000	80:20	0.9913	70:30	0.9942
			90:10				90:10	
Hoaks	80:20	0.9909	70:30	0.9941	70:30	0.9619	90:10	1.0000
	90:10							



Tabel 9. Perbandingan Nilai F1-Score Tertinggi antara Multinomial Naïve Bayes dan AdaBoost

Label	F1-Score			
	skema	MNB	skema	AdaBoost
Non-hoaks	80:20	0.9764	90:10	0.9956
Hoaks	80:20	0.9754	90:10	0.9956

3.5 Deployment

Hasil pengujian menunjukkan bahwa algoritma AdaBoost Classifier memiliki kinerja yang sangat baik dalam mendeteksi berita hoaks berbahasa Indonesia. Pada skema pembagian data 80:20, model ini mencapai akurasi sebesar 0.9879. Sementara itu, nilai *precision* tertinggi sebesar 0.9941 diperoleh pada skema 70:30, nilai *recall* tertinggi mencapai 1.0000 pada skema 90:10, dan nilai *F1-score* tertinggi sebesar 0.9956 diperoleh pada skema 80:20. Secara kuantitatif, nilai akurasi yang tinggi menunjukkan bahwa sebagian besar dokumen berita pada data uji dapat diklasifikasikan dengan benar. Selain itu, nilai *precision* dan *recall* yang sama-sama tinggi mengindikasikan rendahnya tingkat kesalahan klasifikasi, baik *false positive* maupun *false negative*. Hal ini menunjukkan bahwa model AdaBoost tidak hanya akurat dalam memprediksi berita hoaks, tetapi juga mampu mendeteksi hampir seluruh kasus hoaks yang terdapat dalam dataset penelitian ini.

Meskipun nilai performa yang diperoleh tergolong sangat tinggi, potensi terjadinya *data leakage* telah diantisipasi melalui proses pembersihan data yang ketat. Secara khusus, kata-kata atau frasa yang secara eksplisit merujuk pada label hoaks, seperti “hoaks”, “penipuan”, dan istilah sejenis, telah dihapus dari teks berita sebelum proses ekstraksi fitur dilakukan. Langkah ini bertujuan untuk memastikan bahwa model tidak mempelajari pola klasifikasi berdasarkan kata kunci label, melainkan berdasarkan karakteristik semantik dari isi berita. Dengan demikian, hasil yang diperoleh mencerminkan kemampuan klasifikasi yang lebih objektif dan dapat digeneralisasikan.

Dengan performa yang stabil pada berbagai skenario pengujian serta pengendalian risiko kebocoran data, model AdaBoost dinilai layak direkomendasikan pada tahap *deployment* sebagai dasar pengembangan sistem deteksi otomatis berita hoaks berbasis teks berbahasa Indonesia.

4. KESIMPULAN

Penelitian ini membandingkan kinerja algoritma Multinomial Naïve Bayes dan AdaBoost Classifier dalam mendeteksi berita hoaks berbahasa Indonesia dengan menerapkan kerangka kerja CRISP-DM dan representasi fitur TF-IDF. Hasil pengujian pada berbagai skenario pembagian data menunjukkan bahwa AdaBoost memberikan performa terbaik dengan tingkat akurasi tertinggi sebesar 0.9879 pada skema 80:20, sedangkan Multinomial Naïve Bayes memperoleh akurasi tertinggi sebesar 0.9712 pada skema 90:10. Temuan ini menunjukkan bahwa mekanisme *boosting* pada AdaBoost mampu meningkatkan kinerja klasifikasi secara iteratif melalui perbaikan kesalahan dari *weak learner*, sehingga menghasilkan model yang lebih kuat dan stabil. Performa tersebut diperoleh pada dataset berita yang bersumber dari turnbackhoax.id dan detik.com, sehingga dapat disimpulkan bahwa AdaBoost lebih efektif dalam mengklasifikasikan berita hoaks dan non-hoaks berbahasa Indonesia dibandingkan Multinomial Naïve Bayes. Untuk pengembangan penelitian selanjutnya, disarankan untuk mengeksplorasi metode ekstraksi fitur lain, seperti *word embedding*, serta menerapkan pendekatan *deep learning* guna meningkatkan kemampuan model dalam menangkap konteks semantik yang lebih kompleks dan memperluas generalisasi pada berbagai jenis teks berita.

REFERENCES

- [1] E. R. Herman Purba, “Realitas dan Viralitas: Dinamika dan Isu dalam Era Media Baru di Indonesia,” *Kinesik*, vol. 11, no. 03, pp. 283–299, 2024, doi: 10.22487/ejk.v11i3.1213.
- [2] M. A. Maulana and S. Aristi, “Analisis Penentuan Dolus dan Culpa dalam Penyebaran Hoax Melalui Digital,” *J. Multidisiplin West Sci.*, vol. 3, no. 10, pp. 1581–1591, 2024, doi: 10.58812/jmws.v3i10.1612.
- [3] H. A. Taufik Fajar Mustafa, “Klasifikasi Berita Palsu Berbahasa Indonesia Menggunakan Algoritma Naive Bayes Berbasis Web,” *J. Sains Inform. Terap. (JSIT)*, vol. 4, no. 3, pp. 657–663, 2025, doi: 10.62357/jsit.v4i3.564.
- [4] M. R. F. M. Melda Agarina, Sutedi, Arman Suryadi Karim, “Menangkal Hoax dengan Literasi Digital bagi Masyarakat Desa Jati Indah,” *J. Pengabd. Kpd. Masy.*, vol. 2, no. 2, pp. 134–137, 2023, doi: 10.32877/nr.v2i2.744.
- [5] Y. D. Butar, “Analisis Penyebaran Hoax Di Media Sosial Dan Dampaknya Terhadap Masyarakat,” *JPBB*, vol. 3, no. 2, pp. 252–258, 2024, doi: 10.55606/jpbb.v3i2.3201.
- [6] E. W. P. Ikhlasul Amal, “Aplikasi Pendeteksi Berita Palsu Bahasa Indonesia Menggunakan Framework Flask Dan Streamlit Serta Algoritma Machine Learning,” *Univ. Muhammadiyah Surakarta*, pp. 1–18, 2023, [Online]. Available: <http://eprints.ums.ac.id/id/eprint/116531>
- [7] P. Y. R. Athifahputih, “Penegakan Hukum Terhadap Penyebaran Berita Hoax Di Lihat Dari Tinjauan Hukum,” *J. Huk. dan Pembang. Ekon.*, vol. 10, no. 1, pp. 64–76, 2022, doi: 10.20961/hpe.v10i1.62843.
- [8] M. N. Raza, “Sistem Deteksi Berita Hoax Menggunakan Algoritma Naive Bayes Dan Random Forest Pada Machine Learning,” *Pondasi J. Appl. Sci. Eng.*, vol. 1, no. 2, pp. 43–57, 2024, [Online]. Available: <https://journal.alshobar.or.id/index.php/pondasi/article/view/221>
- [9] J. Pareza Alam Jusia, Riza Pahlevi, Daniel Sintong Pardamean Simanjuntak, “Peningkatan Performa Naive Bayes dengan Fitur Chi-Square pada Analisis Sentimen Komentar Pengguna Aplikasi Netflix,” *Bull. Comput. Sci. Res.*, vol. 5, no. 4, pp. 614–621,



- 2025, doi: 10.47065/bulletincsr.v5i4.532.
- [10] U. F. Ayuni Asistiyasari, Bibit Sudarsono, "Klasifikasi Berita Hoaks Menggunakan Algoritma Vector Space Model," *INFOTECHJurnal Inform. Teknol.*, vol. 2, no. 2, pp. 112–119, 2021, doi: 10.37373/infotech.v2i2.176.
- [11] F. Arsyad, N. Hayatin, C. Sri, and K. Aditya, "Deteksi Konten Hoax Pada Media Berita Indonesia Menggunakan Multinomial Naïve Bayes," *Repositor*, vol. 5, no. 4, pp. 921–930, 2023, doi: 10.22219/repositor.v5i4.32092.
- [12] N. S. Isnin Apriyatin Ropikoh, Rijal Abdulhakim, Ultach Enri, "Penerapan Algoritma Support Vector Machine (SVM) untuk Klasifikasi Berita Hoax Covid-19," *J. Appl. Informatics Comput.*, vol. 5, no. 1, pp. 64–73, 2021, doi: 10.30871/jaic.v5i1.3167.
- [13] W. A. Yusuf Kurnia, Ellysha Dwiyanthi Kusuma, Lianny Wydiastuty Kusuma, Suwitno, "Perbandingan Naïve Bayes dan CNN yang Dioptimasi PSO pada Identifikasi Berita Hoax Politik Indonesia," *Bit-Tech (Binary Digit. -Technology)*, vol. 6, no. 3, pp. 340–352, 2024, doi: 10.32877/bt.v6i3.1225.
- [14] N. H. Chita Naully Harahap, Gita Indah Marthasari, "Perbandingan Klasifikasi Berita Hoax Kategori Kesehatan Menggunakan Naive Bayes dan Mltinomial Naive Bayes," *REPOSITOR*, vol. 3, no. 4, pp. 419–424, 2021, doi: 10.22219/repositor.v3i4.31964.
- [15] E. U. Alfin Mahadi, "Analisa Perbandingan Algorithma K-Nearest Neighbors dan Random Forest untuk Klasifikasi Tindakan Medis Persalinan pada Data Kehamilan Multi-Variabel," *Bull. Comput. Sci. Res.*, vol. 5, no. 4, pp. 424–433, 2025, doi: 10.47065/bulletincsr.v5i4.556.
- [16] B. S. A. Ike Verawati, "Algoritma Naïve Bayes Classifier Untuk Analisis Sentiment Pengguna Twitter Terhadap Provider By.u," *J. Media Inform. Budidarma*, vol. 6, no. 3, pp. 1411–1417, 2022, doi: 10.30865/mib.v6i3.4132.
- [17] A. H. M. Wahyu Aji Tri Riswandhana, "Optimalisasi Akurasi Algoritma C4.5 dengan Metode Adaptive Boosting Memprediksi Siswa dalam Menerima Dana Pendidikan," *G-Tech J. Teknol. Terap.*, vol. 8, no. 4, pp. 2895–2902, 2024, doi: 10.70609/gtech.v8i4.5612.
- [18] Y. A. Singgalen, "Penerapan Metode CRISP-DM dalam Klasifikasi Data Ulasan Pengunjung Destinasi Danau Toba Menggunakan Algoritma Naïve Bayes Classifier (NBC) dan Decision Tree (DT)," *J. Media Inform. Budidarma*, vol. 7, no. 3, pp. 1551–1562, 2023, doi: 10.30865/mib.v7i3.6461.
- [19] I. Ade Maysa, Syarifah Putri Agustini Alkadri, "Klasifikasi Tingkat Kepuasan Di Maskapai Penerbangan: Studi Komparasi Algoritma K-NN Dan AdaBoost," *JIP (Jurnal Inform. Polinema)*, vol. 10, no. 3, pp. 405–412, 2023, doi: 10.33795/jip.v10i3.5166.
- [20] I. M. T. Dian Tri Wilujeng, Mohamat Fatekurohman, "Analisis Risiko Kredit Perbankan Menggunakan Algoritma K-Nearest Neighbor dan Nearest Weighted K-Nearest Neighbor," *Indones. J. Appl. Stat.*, vol. 5, no. 2, pp. 142–148, 2023, doi: 10.13057/ijas.v5i2.58426.
- [21] Y. A. Mujaddid Izzul Fikri, Trifebi Shina Sabrila, "Perbandingan Metode Naïve Bayes dan Support Vector Machine pada Analisis Sentimen Twitter," *SMATIKA J.*, vol. 10, no. 02, pp. 71–76, 2020, doi: 10.32664/smatika.v10i02.455.
- [22] N. Y. Rilinka, Indriati, "Analisis Sentimen Penghapusan Ujian Nasional pada Twitter menggunakan Document Frequency Difference dan Multinomial Naïve Bayes," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 3, pp. 876–883, 2021, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/8659>