

Perbandingan Algoritma Support Vector Machine dan Bi-Directional Long Short Term Memory Dalam Mengklasifikasi Berita Hoaks

Siska Merinda, Ciksadan Ciksadan *, Mohammad Fadhli

Teknik Elektro, Sarjana Terapan Teknik Telekomunikasi, Politeknik Negeri Sriwijaya, Palembang, Indonesia

Email: ¹merindasiska49@gmail.com, ^{2,*}ciksadanc@gmail.com, ³mohammad.fadhli@polsri.ac.id

Email Penulis Korespondensi: ciksadanc@gmail.com

Submitted: 19/05/2025; Accepted: 06/06/2025; Published: 13/06/2025

Abstrak—Perkembangan teknologi digital yang sangat cepat telah memberikan kemudahan dalam menyebarkan informasi ke berbagai penjur. Namun, hal ini juga memicu munculnya berita bohong atau hoaks yang dapat membingungkan masyarakat. Penelitian ini dilakukan untuk mengetahui dan membandingkan seberapa baik kinerja dua algoritma pembelajaran mesin, yaitu *Support Vector Machine* (SVM) dan *Bi-Directional Long Short Term Memory* (BiLSTM), dalam mengklasifikasikan berita hoaks dalam bahasa Indonesia. Metode yang digunakan adalah supervised learning, di mana model dilatih menggunakan data yang sudah diberi label hoaks dan non-hoaks. Langkah awal mencakup pengumpulan data dari sumber terpercaya, kemudian dilanjutkan dengan preprocessing seperti pembersihan teks, pemisahan kata (tokenisasi), penghapusan kata tidak penting, serta stemming. Setelah itu, data dibagi menjadi data latih dan data uji dengan perbandingan 80:20. Hasil pengujian menunjukkan bahwa algoritma *Support Vector Machine* mampu mencapai akurasi sebesar 98,46%, dengan precision 98% dan recall 99% pada kategori non-hoaks. Sementara itu, *Bi-Directional Long Short Term Memory* menunjukkan hasil yang lebih unggul, dengan akurasi mencapai 99%, dan precision serta recall sebesar 99% untuk kedua kelas. Dari hasil ini, *Bi-Directional Long Short Term Memory* dianggap lebih efektif dalam memahami konteks bahasa dan mengenali pola dalam berita hoaks. Penelitian ini juga menerapkan model ke dalam sistem berbasis web untuk menguji kemampuannya dalam situasi nyata.

Kata Kunci: Klasifikasi Berita Palsu; Support Vector Machine; Bi-Directional Long Short-Term Memory; Machine Learning; Sistem Deteksi Berita

Abstract—The rapid advancement of digital technology has made it easier to spread information widely and quickly. However, this ease of access has also contributed to the rise of false or misleading news, commonly known as hoaxes, which can confuse the public. This study aims to evaluate and compare the performance of two machine learning algorithms, namely Support Vector Machine (SVM) and Bi-Directional Long Short Term Memory (BiLSTM), in classifying hoax news written in Indonesian. The research adopts a supervised learning approach, where models are trained using pre-labeled data categorized as either hoax or non-hoax. The process begins with collecting data from trusted sources, followed by several preprocessing steps, including text cleaning, tokenization, stopword removal, and stemming. After preprocessing, the dataset is split into training and testing sets in an 80:20 ratio. The results show that the SVM model achieved an accuracy of 98.46%, with 98% precision and 99% recall for the non-hoax category. In comparison, the BiLSTM model performed better, reaching 99% accuracy, with both precision and recall at 99% for both categories. These findings indicate that BiLSTM is more effective at capturing linguistic context and identifying patterns in hoax-related content. Additionally, the models were implemented into a web-based system to assess their real-world detection capabilities.

Keywords: Fake News Classification; Support Vector Machine; Bi-Directional Long Short-Term Memory; Machine Learning; Fake News Detection System

1. PENDAHULUAN

Kemajuan teknologi digital telah membawa perubahan signifikan dalam cara masyarakat memperoleh dan menyebarkan informasi. Kehadiran media sosial, portal berita online, dan aplikasi pesan instan memungkinkan informasi menyebar dengan sangat cepat dan dalam jangkauan yang luas. Namun, kemudahan ini juga memiliki sisi negatif, salah satunya adalah maraknya peredaran berita hoaks atau informasi palsu. Di era digital saat ini, penyebaran hoaks menjadi semakin mudah dan sering kali sulit untuk dikendalikan [1].

Berita hoaks kerap dimanfaatkan untuk membentuk opini publik, menimbulkan kepanikan, serta membawa dampak negatif lainnya. Untuk menangani hal ini, para jurnalis dan lembaga pemeriksa fakta biasanya melakukan verifikasi secara manual. Sayangnya, proses ini sangat menyita waktu dan tenaga, apalagi mengingat jumlah berita yang terus bertambah setiap harinya [2]. Oleh karena itu, dibutuhkan solusi berbasis teknologi seperti kecerdasan buatan (AI). AI sendiri adalah sistem komputer yang dilatih melalui algoritma pembelajaran mesin untuk menyelesaikan masalah-masalah tertentu [2].

Menurut Muhammad Alwi Dahlan, pakar komunikasi dari Universitas Indonesia, hoaks atau berita palsu merupakan bentuk manipulasi informasi yang sengaja dibuat untuk menyesatkan atau membentuk pemahaman yang keliru. Hoaks bisa muncul dalam berbagai bentuk, seperti tulisan, gambar, rekaman suara, maupun video yang telah dimodifikasi sedemikian rupa untuk mengelabui orang yang melihat atau mendengarnya. Umumnya, penyebaran hoaks dilakukan dengan maksud tertentu, seperti meraih keuntungan politik, ekonomi, atau bahkan demi kepentingan pribadi.

Kecerdasan buatan (AI) dan pembelajaran mesin (ML) kini telah mengubah cara kita mengolah informasi dan mengambil keputusan. AI sendiri merujuk pada kemampuan mesin yang dibuat agar bisa meniru cara manusia berpikir dan bertindak, seolah-olah memiliki kecerdasan layaknya manusia [3]. Secara garis besar, *machine learning* atau pembelajaran mesin adalah cabang ilmu yang memungkinkan komputer untuk belajar dari data dan pengalaman, tanpa

harus diberi instruksi secara langsung untuk setiap tugas yang harus dikerjakan (Goodfellow, Bengio, & Courville, 2016). Arthur Samuel, salah satu tokoh awal dalam bidang ini, pernah menyebutkan bahwa machine learning adalah suatu bidang yang membuat komputer mampu belajar tanpa diprogram secara spesifik. Inti dari definisi ini adalah bahwa sistem komputer bisa terus beradaptasi dan meningkatkan kemampuannya seiring bertambahnya data yang diterimanya [4].

Pembelajaran mesin merupakan cabang dari kecerdasan buatan (AI) dan ilmu komputer yang berfokus pada pemanfaatan data serta algoritma untuk meniru cara manusia belajar, dengan tujuan meningkatkan ketepatan kinerjanya secara bertahap. Dalam proses ini, sistem akan mempelajari data yang diberikan dan membentuk sebuah model yang dapat digunakan untuk membuat prediksi atau mengambil keputusan. Teknologi ini memiliki beragam penerapan, mulai dari pengenalan wajah, suara, hingga tulisan tangan.

Secara umum, pembelajaran mesin terbagi ke dalam beberapa kategori, yaitu pembelajaran terawasi, tak terawasi, dan pembelajaran penguatan. Pada pembelajaran terawasi, algoritma dilatih menggunakan data berlabel, sehingga model yang terbentuk dapat digunakan untuk melakukan prediksi berdasarkan data baru. Sementara itu, pembelajaran tak terawasi bekerja dengan data tanpa label untuk menemukan pola tersembunyi di dalamnya. Adapun pembelajaran penguatan melibatkan proses pemberian umpan balik berupa hadiah atau hukuman agar sistem dapat belajar mengambil keputusan yang paling tepat [5].

Deep learning merupakan salah satu subbidang dari *machine learning* yang dikembangkan berdasarkan prinsip kerja dan struktur biologis otak manusia, yang dikenal dengan istilah *artificial neural network* atau jaringan saraf tiruan. Pada penelitian ini, akan dilakukan kajian mendalam terkait *deep learning* yang mencakup definisi, prinsip kerja, arsitektur model, aplikasi di berbagai bidang, serta tantangan yang dihadapi dalam implementasinya.

Secara umum, *deep learning* dapat didefinisikan sebagai pendekatan pembelajaran mesin yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan neuron untuk mengekstraksi fitur kompleks serta merepresentasikan data masukan dalam bentuk hierarki. Perbedaan utama antara *deep learning* dan metode pembelajaran mesin konvensional terletak pada kedalaman serta kompleksitas arsitektur jaringan yang digunakan. Kemampuan *deep learning* dalam mempelajari pola dari data yang kompleks dan abstrak menjadikannya sangat efektif dalam berbagai aplikasi, seperti pengenalan citra, pemrosesan bahasa alami (*natural language processing*), pengenalan suara, dan bidang lainnya [5]. Teknologi ini memungkinkan mesin belajar meniru cara manusia dalam melakukan sesuatu, seolah-olah sedang mencontoh perilaku manusia. Contoh penerapannya bisa dilihat pada mobil tanpa pengemudi, di mana sistem mampu mengenali bentuk jalan, memahami arah belokan ke kanan atau kiri, membaca rambu lalu lintas, serta membedakan antara pejalan kaki dan benda lain seperti tiang lampu (Goldberg, 1989) [6].

Dalam beberapa penelitian terdahulu yang relevan, ditemukan beberapa temuan penting. Salah satunya pada penelitian yang dilakukan oleh Alifia Zahra, M. Nurkamal Fauzan tahun 2022 [7] Dalam penelitian ini, dilakukan pengujian untuk mengklasifikasikan berita ke dalam kategori fakta atau hoaks menggunakan algoritma Multinomial Naïve Bayes. Algoritma ini sering dimanfaatkan dalam tugas klasifikasi, khususnya untuk data berbasis teks. Sebanyak 500 data berita dikumpulkan melalui proses *crawling* menggunakan Twitter API dengan kata kunci "berita". Data tersebut kemudian diproses terlebih dahulu dan diberi label sebelum digunakan untuk pelatihan dan pengujian model. Hasil dari uji coba menunjukkan bahwa model ini mampu mencapai tingkat akurasi sebesar 83% pada data uji, sementara pada data pelatihan mencapai akurasi hingga 94%.

Penelitian lainnya yang dilakukan oleh Aisyah Awalina, Fitra A. Bachtiar, Indriati pada tahun 2022 [8], Informasi ulasan sangat membantu pengunjung mengenal layanan suatu tempat, namun ulasan palsu sering disalahgunakan. Penelitian ini menggunakan algoritma *Support Vector Machine* (SVM) untuk mengklasifikasikan ulasan palsu, dengan mengatasi ketidakseimbangan data melalui metode *Borderline Over-sampling* (BOS). Proses dimulai dari *preprocessing*, pembobotan TF-IDF, penambahan fitur sentimen, penyeimbangan data dengan BOS, lalu klasifikasi oleh SVM. Data dibagi 80% untuk pelatihan dan 20% untuk pengujian, dengan pencarian parameter terbaik menggunakan *5-fold cross-validation*. Hasil terbaik didapat saat $N = 400%$, dengan akurasi 78,6%, precision 19,7%, recall 17,1%, f-measure 14,4%, dan g-mean 32%. BOS terbukti meningkatkan performa klasifikasi. Penelitian ini juga menyarankan penggunaan algoritma lain seperti genetic algorithm agar proses pencarian parameter lebih cepat dan efisien, karena saat ini masih memerlukan waktu hingga 10 jam untuk satu pengujian [8].

Penelitian yang dilakukan oleh Grace Elisabeth, Rahma Salsa Bilah, Siska Nova Ardini, Nova Agustina, Danny Aidil Rismayadi tahun 2023 [9], Penting adanya suatu sistem yang mampu membantu mengidentifikasi dan memilah berita palsu, khususnya yang berkaitan dengan isu kenaikan harga BBM. Salah satu pendekatan yang ditawarkan untuk menangani masalah ini adalah dengan memanfaatkan algoritma *Support Vector Machine* (SVM), yang dikenal cukup handal dalam melakukan klasifikasi data, termasuk dalam membedakan antara berita yang valid dan yang menyesatkan. Penelitian ini dimulai dengan proses pengumpulan data yang relevan agar mencerminkan kondisi nyata terkait isu kenaikan BBM. Setelah data diperoleh, langkah berikutnya adalah melakukan *preprocessing* guna membersihkan dan mempersiapkan data agar layak untuk digunakan dalam pemodelan. Dataset kemudian dibagi menjadi dua bagian: satu untuk melatih model (*training data*), dan satu lagi untuk menguji keakuratannya (*testing data*). Model SVM dijalankan dengan menggunakan data latih tersebut, lalu diuji dengan data uji untuk melihat sejauh mana kemampuannya dalam mengklasifikasikan berita secara tepat. Dari hasil pengujian, diperoleh bahwa SVM mampu memberikan akurasi yang cukup baik dalam membedakan berita hoaks dari berita faktual, khususnya terkait topik kenaikan harga BBM. Pada kasus berita mengenai "Harga BBM solar Pertamina dan Shell naik per 1 November 2022", model memprediksi bahwa berita tersebut tergolong palsu, dengan probabilitas 91,27% untuk kategori hoaks,

dan hanya 8,73% untuk kategori benar. Temuan ini memperkuat potensi penggunaan *Support Vector Machine* sebagai alat bantu yang efektif dalam menyaring informasi palsu [9]. Langkah selanjutnya yang perlu dilakukan setelah pengujian adalah mengimplementasikan model tersebut dalam skala yang lebih luas, agar publik bisa lebih yakin terhadap informasi yang mereka terima. Dengan begitu, penyebaran berita palsu dapat diminimalisir dan masyarakat dapat memperoleh informasi yang telah melalui proses verifikasi yang ketat.

Penelitian oleh Muhammad Fadhil Muttaqin, Tatang Bukhori, Yanto, Nova Agustina, Muchammad Naseer pada tahun 2023 [10], berdasarkan hasil pengujian, model klasifikasi yang dibangun dengan *Support Vector Machine* menunjukkan tingkat akurasi sebesar 78%. Setelah model dilatih dan diuji, tahap selanjutnya adalah mengimplementasikannya ke dalam sebuah situs web yang dapat digunakan masyarakat untuk memeriksa keaslian judul berita. Dalam aplikasi tersebut, pengguna tidak hanya mendapatkan hasil klasifikasi apakah suatu berita tergolong "Fake" atau "True", tetapi juga ditampilkan persentase keyakinan model terhadap prediksi tersebut. Dengan adanya sistem ini, diharapkan masyarakat dapat memperoleh informasi yang lebih valid mengenai Covid-19 dan tidak mudah terpengaruh oleh kabar yang tidak dapat dipertanggungjawabkan. Model yang telah dibuat kemudian disimpan dalam format .pkl (pickle) agar bisa digunakan dalam proses pengembangan aplikasi web. Meskipun hasil yang diperoleh cukup baik, penelitian ini belum sepenuhnya sempurna dan masih memiliki ruang untuk perbaikan. Oleh karena itu, penulis menyarankan agar penelitian selanjutnya mempertimbangkan penggunaan algoritma lain, seperti Naïve Bayes atau Decision Tree, yang mungkin dapat meningkatkan tingkat akurasi model. Harapannya, penggunaan metode yang berbeda dapat menghasilkan model yang lebih optimal dalam mendeteksi berita palsu [10].

Penelitian lainnya, yang dilakukan oleh Puji Ayuningtyasa, Henri Tantyokoa pada tahun 2024 [11], penelitian ini membandingkan algoritma BiLSTM dan *Support Vector Machine* untuk klasifikasi ulasan aplikasi LinkAja. Data sebanyak 35.560 baris dikumpulkan melalui *crawling* dan dilabeli menjadi dua kelas: positif dan negatif. Vektorisasi teks dilakukan dengan *Word2Vec* (skip-gram), dan model *Bidirectional Long Short Term Memory* dibangun dengan tiga lapisan utama. *Support Vector Machine* menggunakan kernel RBF. Hasil akhir menunjukkan *Bidirectional Long Short Term Memory* memiliki akurasi 0,9505, lebih tinggi dibanding *Support Vector Machine* yang mencapai 0,93, sehingga *Bidirectional Long Short Term Memory* dinilai lebih akurat dalam klasifikasi data ini.

Penelitian ini dilakukan dengan tujuan untuk melihat dan membandingkan seberapa baik kinerja dua algoritma klasifikasi, yaitu *Support Vector Machine* dan *Bidirectional Long Short Term Memory*, dalam mengklasifikasi berita hoaks pada sebuah dataset yang memang sudah dilabeli sebagai hoaks atau bukan hoaks. Fokus utama dari penelitian ini berada pada pendekatan *Supervised Learning*, yaitu metode pembelajaran mesin yang menggunakan data yang sudah memiliki label untuk melatih model agar mampu mengenali pola tertentu dalam teks. *Supervised learning* adalah salah satu pendekatan dalam *machine learning* di mana model belajar dari data yang sudah memiliki label atau jawaban yang benar. Dalam proses ini, setiap data pelatihan terdiri dari pasangan input dan output yang diketahui. Tujuannya adalah agar model bisa mengenali pola dari data tersebut, sehingga nantinya mampu memprediksi label atau hasil dari data baru yang belum pernah dilihat sebelumnya [4].

Dalam pelaksanaannya, peneliti menggunakan data berita yang telah dikategorikan, kemudian diterapkan ke dua metode klasifikasi tersebut. Dengan pendekatan ini, model diharapkan dapat belajar membedakan antara berita hoaks dan berita yang valid. *Support Vector Machine* dipilih karena dikenal efektif dalam menangani data dengan dimensi tinggi seperti teks, sementara *Bidirectional Long Short Term Memory* dipilih karena kemampuannya dalam menangani konteks kalimat secara lebih mendalam dari dua arah, yang sangat berguna dalam memproses informasi berbasis teks. Adapun tujuan akhirnya adalah untuk mengetahui algoritma mana yang memberikan hasil paling akurat dalam klasifikasi berita hoaks, berdasarkan dataset yang digunakan. Harapannya, hasil dari penelitian ini bisa menjadi acuan awal dalam pemilihan algoritma yang tepat untuk diterapkan pada sistem deteksi hoaks, khususnya dalam bahasa Indonesia, serta dapat dikembangkan lebih lanjut untuk kebutuhan aplikasi yang lebih luas di bidang pemantauan informasi digital.


Meskipun telah ada berbagai penelitian yang menggunakan algoritma machine learning seperti Naïve Bayes, Random Forest, dan *Support Vector Machine* dalam mendeteksi berita hoaks, sebagian besar dari penelitian tersebut hanya membahas satu algoritma secara terpisah dan belum membandingkannya secara langsung dengan metode deep learning yang memiliki kemampuan memahami konteks bahasa secara lebih dalam. Selain itu, kebanyakan studi sebelumnya juga belum menguji model yang dikembangkan dalam kondisi nyata, misalnya dengan mengintegrasikannya ke dalam sebuah sistem atau aplikasi yang dapat digunakan secara langsung oleh pengguna. Oleh karena itu, penelitian ini mencoba mengisi kekosongan tersebut dengan melakukan perbandingan antara algoritma klasifikasi tradisional, yaitu SVM, dan algoritma deep learning, yaitu *Bidirectional Long Short Term Memory*, khususnya dalam konteks berita berbahasa Indonesia. Penelitian ini juga sekaligus mengimplementasikan model ke dalam sistem berbasis web untuk melihat bagaimana kinerja model dalam mendeteksi berita hoaks secara langsung di lingkungan nyata.

2. METODOLOGI PENELITIAN

Penelitian ini dilakukan untuk membandingkan kinerja dua model klasifikasi teks dalam mengidentifikasi berita hoaks, yaitu *Support Vector Machine* dan *Bidirectional Long Short-Term Memory*. Penelitian dirancang melalui beberapa tahapan utama, mulai dari pengumpulan data, proses pembersihan teks (*preprocessing*), transformasi data

ke dalam bentuk *numerik* (vektorisasi), pelatihan model, hingga evaluasi performa. Gambar 1 menyajikan alur lengkap proses penelitian, termasuk penerapan metode klasifikasi pada masing-masing model.

Alur tahapan penelitian ini dijelaskan secara rinci dalam Gambar 1, yang mencakup proses awal hingga pengujian akhir model klasifikasi menggunakan *Support Vector Machine* dan *Bidirectional Long Short Term Memory*.



Gambar 1. Kerangka Penelitian

Gambar 1 dimulai dengan langkah awal “start”, yang di mana menunjukkan awal dari tahapan proses penelitian. Kemudian, dilakukan langkah “studi literatur”, di mana peneliti melakukan pengumpulan referensi terkait berita hoaks, *machine learning*, *deep learning*, untuk menemukan *State Of The Art (SOTA)* dan gap penelitian. Selanjutnya, melakukan pengumpulan terhadap dataset yang dibutuhkan, mengumpulkan berita hoaks yang terdiri dari hoaks dan *non*-hoaks. Kemudian memproses dataset untuk dibersihkan dan mengubah menjadi format yang lebih sesuai untuk analisis. Langkah selanjutnya, merancang model untuk klasifikasi dari hasil dataset yang telah diproses untuk menguji model tersebut. Kemudian, dilanjutkan dengan pengujian cobaan model, tujuan dari uji coba model adalah untuk mengevaluasi sejauh mana model yang dikembangkan dapat menghasilkan prediksi yang akurat dan dapat diandalkan. Langkah selanjutnya adalah analisis hasil dan penyusunan kesimpulan yang akan dibahas pada bab selanjutnya. Terakhir, setelah semua tahapan sebelumnya selesai, dapat dilanjutkan ke tahapan selanjutnya. Secara keseluruhan, kerangka penelitian ini menggambarkan tahapan yang harus diikuti untuk melatih dan menguji algoritma *Support Vector Machine* dan *Bidirectional Long Short Term Memory* yang telah di input dan di preproses.

2.1 Pengumpulan Dataset

Dalam penelitian ini, data yang digunakan berasal dari 19.264 berita berbahasa Indonesia yang mencakup campuran antara berita hoaks dan *non*-hoaks. Data tersebut dihimpun dari berbagai sumber yang dapat dipercaya, seperti situs *turnbackhoax.id* serta beberapa repositori terbuka, termasuk *Kaggle* dan *GitHub* [12]. Setelah dilakukan proses pembersihan dan seleksi, sebanyak 5.000 data dipilih sebagai sampel akhir, terdiri dari 2.500 berita hoaks dan 2.500 *non*-hoaks. Jumlah ini dibatasi agar proporsi data tetap seimbang dan proses pelatihan maupun evaluasi model dapat berjalan lebih efisien secara komputasi.

2.2 Preprocessing Data

Preprocessing data adalah tahap awal yang dilakukan untuk mengubah data mentah menjadi data yang lebih siap digunakan dalam proses analisis atau pemodelan. Dataset yang telah dikumpulkan akan diproses terlebih dahulu melalui tahapan *preprocessing*, yaitu proses pembersihan data dari gangguan atau elemen-elemen yang tidak relevan agar data menjadi lebih rapi dan siap digunakan untuk analisis lebih lanjut [13]. Tujuannya adalah agar data tersebut lebih rapi, terstruktur, dan mudah diproses di tahap selanjutnya [14].

Alur tahapan penelitian ini dijelaskan secara rinci dalam Tabel 1, yang mencakup proses awal hingga pengujian akhir model klasifikasi menggunakan *SVM* dan *BiLSTM*.

Tabel 1. Preprocessing Data

Teks Asli	Cleaning Text	Tokenisasi	Removal Stopword	Stemming
Vaksin COVID-19 disuntikkan ke tubuh manusia menyebabkan kematian dalam 2 tahun.	vaksin covid disuntikkan ke tubuh manusia menyebabkan kematian dalam 2 tahun	['vaksin', 'covid', 'disuntikkan', 'ke', 'tubuh', 'manusia', 'menyebabkan', 'kematian', 'dalam', 'tahun']	['vaksin', 'covid', 'disuntikkan', 'menyebabkan', 'kematian']	['vaksin', 'covid', 'suntik', 'tubuh', 'manusia', 'sebab', 'mati']

Dalam penelitian ini, proses preprocessing dilakukan melalui empat langkah utama, yaitu:



- a. *Pembersihan Teks (Cleaning)*
 Pada tahap ini, karakter-karakter khusus seperti tanda baca, simbol, serta angka yang tidak diperlukan untuk analisis akan dibersihkan dari data. Selain itu, seluruh teks diubah menjadi huruf kecil agar format penulisannya seragam dan memudahkan proses analisis selanjutnya[15]. Tujuannya agar teks menjadi lebih bersih dan mudah dianalisis.
- b. *Tokenisasi*
 Proses tokenisasi dilakukan untuk memisahkan teks menjadi kata-kata satuan. Setelah itu, dilanjutkan dengan menghapus kata-kata yang dianggap tidak penting, seperti kata hubung, karena tidak memiliki makna khusus dalam analisis data [16].Langkah ini bertujuan untuk memecah teks menjadi bagian-bagian kecil, seperti kata atau frasa. Dengan begitu, setiap elemen dalam teks dapat diproses oleh algoritma pembelajaran mesin secara lebih efisien.
- c. *Penghapusan Stopword (Removal Stopword)*
 Menghapus kata-kata umum yang tidak memiliki kontribusi penting terhadap makna teks menggunakan pustaka NLTK. Dalam proses ini, kata-kata yang sering muncul namun tidak memiliki pengaruh besar terhadap makna teks seperti “dan”, “atau”, “dengan” akan dihapus. Hal ini dilakukan agar model hanya fokus pada kata-kata yang benar-benar penting untuk klasifikasi
- d. *Stemming*
 Mengembalikan kata ke bentuk dasarnya menggunakan stemmer Bahasa Indonesia dari Sastrawi. Dengan menyederhanakan berbagai variasi kata yang sebenarnya memiliki arti serupa, proses analisis bisa menjadi lebih efisien. Pada proses ini, akhiran kata dihapus agar model lebih mudah mengenali makna dan keterkaitan antar kata. Hasilnya, model dapat memahami konteks teks dengan lebih baik dan meningkatkan akurasi dalam analisis data [17].

Teks yang telah melalui proses pembersihan selanjutnya diubah ke dalam bentuk numerik agar dapat diproses oleh algoritma pembelajaran mesin. Teknik vektorisasi yang digunakan berbeda pada masing-masing model:

- a. Pada *Support Vector Machine*, digunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF) untuk merepresentasikan pentingnya suatu kata dalam dokumen terhadap seluruh korpus.
- b. Pada *Bidirectional Long Short Term Memory*, teks diubah menjadi urutan token (angka) menggunakan *Tokenizer* dari Keras, kemudian diproses menjadi word embedding dengan panjang vektor 100 dimensi dan panjang sekuens maksimum 100 token.

Dataset yang telah diproses dibagi menjadi dua bagian untuk keperluan pelatihan dan pengujian. Pembagian ini dilakukan secara acak menggunakan fungsi `train_test_split` dari pustaka *Scikit-learn*, dengan proporsi sebagai berikut:

- a. 80% untuk pelatihan (*training set*)
- b. 20% untuk pengujian (*testing set*)

Proporsi ini digunakan secara konsisten untuk kedua model *Support Vector Machine* dan *Bidirectional Long Short Term Memory* guna memastikan perbandingan performa yang adil.

2.3 Merancang Model

Pada tahap perancangan model, proses dimulai dengan menerima data masukan berupa kumpulan berita. Data ini kemudian melalui beberapa langkah praproses yang bertujuan untuk membersihkan dan menyiapkannya agar lebih mudah diproses oleh algoritma. Langkah awal melibatkan pembersihan teks dari simbol, angka, dan karakter khusus. Selanjutnya, teks dipisahkan menjadi kata-kata (tokenisasi), lalu kata-kata umum yang tidak terlalu berpengaruh dalam analisis seperti “dan” atau “dengan” dihapus (stopword removal). Setelah itu, setiap kata diubah ke bentuk dasarnya melalui proses stemming dan lemmatization. Data yang telah dibersihkan lalu dibagi menjadi dua bagian: data untuk pelatihan dan data untuk pengujian. Pada tahap pelatihan, data digunakan untuk melatih dua model berbeda, yakni *Support Vector Machine (SVM)* dan *Bi-Directional Long Short Term Memory (Bi-LSTM)*. Kedua model ini kemudian dievaluasi melalui proses validasi untuk melihat seberapa baik keduanya dalam mengklasifikasikan berita hoaks. Perancangan ini dirancang agar kedua algoritma dapat diuji secara adil dengan data yang sama, sehingga hasil perbandingan akurasi menjadi lebih objektif.

Tabel 2. Konfigurasi Model *Support Vector Machine*

Komponen	Deskripsi
vektorisasi	TF=IDF, max_feats=3000
kernel	linear
Nilai C	0.05
Class Weight	Balanced
<i>Probabilistic Output</i>	Ya (<i>probability =True</i>)
Evaluasi Model Framework	<i>Cross-Validation 5-fold Scikit-Learn</i>

Pada Tabel 2 ini menjelaskan mulai dari metode vektorisasi menggunakan TF-IDF, jenis kernel yang dipilih, hingga proses evaluasi menggunakan validasi silang lima kali lipat. Konfigurasi ini bertujuan untuk mendapatkan kinerja terbaik dengan tetap mempertimbangkan efisiensi pemrosesan.

Tabel 3. Arsitektur Model *Bidirectional Long Short Term Memory*

Arsitektur	Konfigurasi
<i>Embedding</i>	<i>Dimensi vector</i> : 100
BiLSTM layer 1	64 units, <i>return_sequences=True</i>
Dropout 1	0.2
Bilstm Layer 2	32 Units
Dropout 2	0.2
Dense Layer	16 units, aktivasi ReLU

Pada Tabel 3 di dalamnya terdapat rincian struktur layer yang digunakan, termasuk embedding layer, dua lapisan BiLSTM bertingkat, dropout, serta dense layer. Setiap konfigurasi dirancang agar model dapat memahami konteks kalimat secara mendalam dan mengurangi risiko overfitting.

2.4 Support Vector Machine

Support Vector Machine (SVM) adalah metode klasifikasi dalam supervised learning yang dibangun berdasarkan gabungan berbagai teori komputasi lama, seperti konsep margin dan hyperplane yang sudah dikenalkan oleh Aronszajn pada tahun 1950, serta beberapa teori pendukung lainnya. Dalam penerapannya, *Support Vector Machine* membutuhkan dua jenis data pelatihan, yaitu data positif dan data negatif. Kedua jenis data ini digunakan untuk membantu *Support Vector Machine* menentukan batas pemisah terbaik di ruang berdimensi banyak yang disebut hyperplane. Secara sederhana, *Support Vector Machine* bekerja dengan cara mencari garis atau bidang pemisah yang optimal dan memastikan jarak antara dua kelompok data tersebut (margin) sebesar mungkin agar klasifikasi menjadi lebih akurat [18].

2.5 Bidirectional Long Short term Memory

Deep learning adalah pendekatan dalam pembelajaran mesin yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan untuk memproses dan memahami data yang rumit. Setiap lapisan dalam jaringan ini bekerja untuk menangkap pola atau ciri penting dari data, mulai dari yang paling sederhana hingga yang lebih kompleks. Yang membedakan *deep learning* dari metode pembelajaran mesin biasa adalah jumlah lapisan dan tingkat kompleksitasnya. Karena kemampuannya dalam mengenali pola dari data yang bersifat *abstrak*, *deep learning* banyak digunakan di berbagai bidang seperti pengenalan gambar, pengolahan bahasa alami, hingga pengenalan suara [5].

2.6 Uji Coba

Penelitian ini menguji beberapa algoritma klasifikasi untuk menentukan model terbaik dalam mendeteksi berita hoaks. Evaluasi dilakukan menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score*. Setelah menemukan algoritma dengan performa terbaik, model diuji kembali menggunakan data baru dan diintegrasikan ke dalam sistem web untuk melihat kemampuannya dalam mendeteksi hoaks secara nyata.

Tabel 4. Confusion Matrix

	FALSE POSITIVE (FP)	FALSE NEGATIVE (FN)
TRUE POSITIVE	TP	FN
TRUE NEGATIVE	FP	TN

Tabel 4 menggambarkan struktur dasar confusion matrix yang menjadi dasar evaluasi model klasifikasi. Dalam tabel ini, diperlihatkan hubungan antara prediksi dan label sebenarnya, termasuk *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Komponen ini sangat penting untuk menghitung metrik seperti *precision*, *recall*, dan *F1-score*.

Confusion matrix divisualisasikan dalam bentuk heatmap untuk mempermudah pemahaman terhadap kesalahan prediksi yang dilakukan oleh model. Visualisasi ini menunjukkan seberapa akurat model memprediksi setiap kategori dibandingkan dengan label sebenarnya dari data [19].

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \tag{1}$$

Persamaan (2) digunakan untuk menghitung *precision*, yaitu rasio antara jumlah prediksi positif yang benar dengan seluruh prediksi yang diklasifikasikan sebagai positif. Nilai ini diperoleh dengan membagi jumlah *true positive* (TP) yaitu ketika model berhasil mengenali data positif dengan tepat dengan total prediksi positif, yaitu TP ditambah *false positive* (FP). FP sendiri merupakan kondisi ketika model secara keliru mengklasifikasikan data negatif sebagai positif. Dengan kata lain, *precision* menunjukkan seberapa akurat model dalam memprediksi data sebagai positif. Semakin tinggi nilai *precision*, maka semakin kecil kemungkinan model melakukan kesalahan dalam mendeteksi data

negatif sebagai positif, yang sangat penting terutama ketika kesalahan prediksi tersebut dapat menimbulkan dampak besar [20].

$$Presisi = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

Persamaan (3) digunakan untuk menghitung nilai recall, yaitu ukuran seberapa banyak sampel positif yang berhasil dikenali dengan benar oleh model dari seluruh sampel positif yang ada. Nilai ini diperoleh dengan membagi jumlah true positive (TP) yaitu jumlah kasus positif yang diklasifikasikan dengan benar dengan total kasus positif sebenarnya, yakni gabungan antara TP dan *false negative* (FN). FN sendiri adalah kasus positif yang tidak berhasil dikenali oleh model. Semakin besar nilai *recall*, maka semakin baik kemampuan model dalam mendeteksi data yang tergolong positif [20].

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

Persamaan (4) digunakan untuk menghitung nilai *F1-Score*, yaitu metrik evaluasi yang menggabungkan *precision* dan *recall* dalam satu ukuran. Nilai ini akan optimal jika kedua metrik tersebut sama-sama tinggi. Tujuan dari perhitungan ini adalah untuk menjaga keseimbangan antara ketepatan dan kemampuan model dalam mengenali data positif. *Precision* menunjukkan seberapa akurat model dalam memprediksi data positif, sementara *recall* menunjukkan seberapa baik model mengenali seluruh data positif yang sebenarnya ada. *F1-Score* dihitung sebagai rata-rata harmonis dari kedua nilai tersebut, sehingga memberikan gambaran menyeluruh tentang kinerja model klasifikasi [20].

$$F-1\ score = \frac{1}{2} \left(\frac{1}{Precision} + \frac{1}{Recall} \right) \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengolahan Data

Penelitian ini membandingkan dua algoritma dalam machine learning, yaitu *Support Vector Machine* (SVM) dan *Bidirectional Long Short-Term Memory* (BiLSTM), untuk mendeteksi berita hoaks dalam Bahasa Indonesia. Sebanyak 5.000 data digunakan, yang sebelumnya telah diproses dan kemudian dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian.

3.2 Tahapan Penerapan Metode

3.2.1 Tahapan Penerapan Algoritma *Support Vector Machine* (SVM)

Algoritma *Support Vector Machine* dalam penelitian ini diterapkan dengan mengubah teks hasil preprocessing menjadi fitur numerik menggunakan TF-IDF. Model dibangun menggunakan Scikit-learn dengan kernel linear dan parameter $C=0.05$, serta penyesuaian *class_weight* agar mampu menangani distribusi data yang seimbang. Proses pelatihan menggunakan data sebanyak 4.000 sampel, diuji dengan 1.000 data, dan melibatkan validasi silang 5-fold. Hasil pengujian menunjukkan akurasi sebesar 98,46% dengan *precision* dan *recall* yang tinggi. Dari segi efisiensi, pelatihan model ini memerlukan waktu sekitar 4 jam 43 menit. Meskipun cukup lama, *Support Vector Machine* tetap lebih ringan secara komputasi dibandingkan model *Support Vector Machine* dan menghasilkan performa yang solid. *Tokenisasi dan Embedding*. Teks yang telah dilakukan preprocessing kemudian dikonversi menjadi urutan indeks angka dengan menggunakan *tokenizer* dari *framework* keras. Kemudian, kata tersebut diubah menjadi vektor menggunakan embedding layer berdimensi 100.

100%  5000/5000 [4:53:23<00:00, 1.69s/it]

Gambar 2. Hasil Waktu Pelatihan Model *Support Vector Machine*

Gambar 2 ini menunjukkan total waktu yang dibutuhkan untuk menyelesaikan pelatihan 5.000 data, memberikan gambaran efisiensi dari segi komputasi.

3.2.2 Tahapan Penerapan Algoritma *Bidirectional Long Short Term Memory*

Penerapan *Bidirectional Long Short Term Memory* dilakukan menggunakan Keras dengan TensorFlow sebagai backend. Teks diubah menjadi urutan token dan diproses ke dalam embedding vektor berdimensi 100. Arsitektur model terdiri dari dua lapisan *Bidirectional Long Short Term Memory* bertingkat, masing-masing dengan dropout untuk mencegah overfitting, lalu diteruskan ke dense layer untuk klasifikasi. Model dilatih selama 100 *epoch* dengan batch size 32. Dari 5.000 data, 4.000 digunakan untuk pelatihan dan sisanya untuk pengujian. *Bidirectional Long Short Term Memory* menunjukkan akurasi 99% dan performa stabil di semua metrik evaluasi. Proses pelatihan memakan waktu sekitar 6 jam, sedikit lebih lama dari *Support Vector Machine*, namun sebanding dengan kemampuannya dalam memahami konteks kalimat secara lebih dalam.

100% 5000/5000 [5:42:08<00:00, 1.93s/it]

Gambar 3. Hasil Waktu Pelatihan dan Pengujian *Bidirectional Long Short Term Memory*

Gambar 3 memperlihatkan durasi pelatihan sekaligus pengujian untuk model BiLSTM. Waktu ini sedikit lebih lama dibandingkan SVM, mencerminkan kompleksitas arsitektur jaringan dan proses pembelajaran kontekstual dua arah.

3.3 Hasil Pengujian *Support Vector Machine (SVM)*

Pada penelitian ini, dilakukan penggunaan model *Support Vector Machine (SVM)* untuk mengklasifikasikan berita ke dalam dua kategori, yaitu hoaks dan non-hoaks. Berdasarkan hasil evaluasi menggunakan classification report, model SVM menunjukkan performa yang sangat baik dengan tingkat akurasi mencapai 98,46%. Nilai precision dan recall pada masing-masing kelas juga tinggi, yang menunjukkan kemampuan model dalam memprediksi dengan tepat sekaligus mengenali data yang relevan secara konsisten. Untuk kategori non-hoaks, precision tercatat sebesar 0,98 dan recall sebesar 0,99, sedangkan untuk kategori hoaks, precision mencapai 0,99 dan recall sebesar 0,98. Nilai f1-score pada kedua kelas pun hampir sempurna, masing-masing berada di angka 0,99 dan 0,98.

Tabel 5. Hasil *Classification Report Support Vector Machine*


Label	Precision	Recall	F1-Score	Support
Non-Hoaks	0.98	0.99	0.99	500
Hoaks	0.98	0.98	0.98	500
<i>Accuracy</i>			0.98	1000
Macro Avg	0.98	0.98	0.98	1000
Weighted Avg	0.98	0.98	0.98	1000

Tabel 5 menunjukkan bahwa model SVM memiliki performa sangat baik pada data uji. Pada kelas Non-Hoaks, recall mencapai 0,99, sedangkan pada kelas Hoaks, precision dan recall sama-sama tinggi di angka 0,98. Nilai f1-score sebesar 0,98 di kedua kelas mencerminkan keseimbangan antara ketepatan dan kemampuan mendeteksi data. Macro dan weighted average yang stabil menunjukkan performa model yang konsisten meskipun ada ketidakseimbangan jumlah data antar kelas. Hasil ini diperkuat oleh confusion matrix: dari 1.000 data uji, model berhasil mengklasifikasikan 496 data Non-Hoaks dan 488 data Hoaks dengan benar, dengan total kesalahan hanya 16 data. Data uji diperoleh dari pembagian 5.000 data dengan rasio 80:20 menggunakan fungsi `train_test_split` dari *Scikit-learn*.

Tabel 6. Hasil *Confussion Matrix Support Vector Machine*

	Prediksi Non-Hoax	False Negative (FN)
Actual Non-Hoax	488	12
Actual Hoax	4	496

Tabel 6 ini terlihat bahwa model mampu mengklasifikasikan sebagian besar data dengan benar, meskipun masih terdapat sejumlah kecil *false negative* dan *false positive*.



Gambar 4. *Confusion Matrix Support Vector Machine*

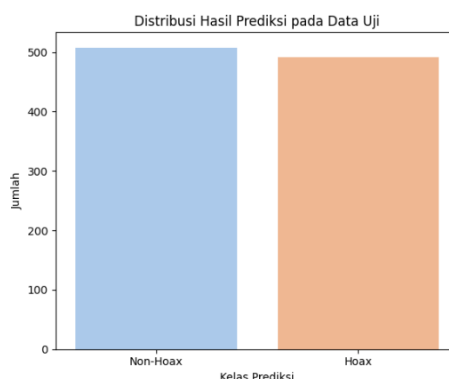
Gambar 4 menyajikan perbandingan antara label aktual dan hasil prediksi SVM dalam bentuk heatmap. Ini memudahkan pembaca untuk melihat pola klasifikasi dan jenis kesalahan yang terjadi.

$$Akurasi = \frac{488+496}{488+496+4+12} \times 100\% = 0.984$$

$$Presisi = \frac{TP}{TP+FP} \times 100\% = \frac{488}{488+4} \times 100\% = 0.9918$$

$$Recall = \frac{TP}{TP+FN} \times 100\% = \frac{488}{488+12} \times 100\% = 0.976$$

$$F1 - Score = 2 \times \frac{precision \times recall}{precision+recall} = 2 \times \frac{0.9918 \times 0.976}{0.9918+0.976} = 2 \times \frac{0.9679}{1.9678} = 2 \times 0.4918 = 0.9837$$



Gambar 5. Hasil Prediksi Hasil Uji Data *Support Vector Machine*

Pada Gambar 5, grafik ini menggambarkan seberapa banyak data uji yang diprediksi oleh model SVM sebagai berita hoaks dan non-hoaks. Terlihat bahwa jumlah prediksi untuk masing-masing kelas cukup seimbang, yaitu sekitar 508 untuk non-hoaks dan 492 untuk hoaks. Keseimbangan jumlah prediksi ini menunjukkan bahwa model bekerja secara adil dalam mengenali kedua jenis berita, tanpa memihak salah satu kelas. Hal ini menjadi indikator bahwa model SVM yang digunakan cukup andal dalam mengelompokkan berita sesuai kategorinya pada data yang belum pernah dilihat sebelumnya.

3.4 Hasil Pengujian *Bidirectional Long Short Term Memory (BILSTM)*

Pada penelitian ini, digunakan model *Bidirectional Long Short Term Memory* untuk mengklasifikasikan berita hoaks dan non-hoaks berbasis teks berbahasa Indonesia. Dataset yang digunakan berjumlah 5.000 data, yang kemudian dibagi menggunakan skema 80:20, yaitu 4.000 data untuk pelatihan (training) dan 1.000 data untuk pengujian (*testing*). Pembagian ini dilakukan secara acak untuk memastikan model diuji dengan data yang belum pernah dikenali sebelumnya. Hasil evaluasi menunjukkan bahwa model *Bidirectional Long Short Term Memory* memiliki performa yang sangat baik.

Tabel 7. *Classification Report Bidirectional Long Short Term Memory*


Label	Precision	Recall	F1-Score	Support
Non-Hoaks	0.99	0.99	0.99	500
Hoaks	0.99	0.99	0.99	500
Accuracy			0.99	1000
Macro Avg	0.99	0.99	0.99	1000
Weighted	0.99	0.99	0.99	1000

Berdasarkan hasil evaluasi pada Tabel 7 *Classification Report*, model *Bidirectional Long Short Term Memory* menunjukkan performa yang sangat baik dalam mengklasifikasikan berita hoaks dan non-hoaks, dengan *precision*, *recall*, dan F1-score sebesar 0,99 untuk masing-masing kelas. Nilai *precision* tersebut menunjukkan bahwa prediksi berita hoaks oleh model sangat akurat, dengan tingkat kesalahan false positive yang sangat rendah, sementara nilai *recall* menandakan bahwa model mampu mengenali hampir seluruh berita hoaks yang ada dalam data uji, dengan sedikit kesalahan *false negative*. F1-score yang tinggi memperkuat bahwa model tidak hanya akurat, tetapi juga seimbang dalam menangani kedua jenis kesalahan. Selain itu, nilai macro average dan weighted average yang juga mencapai 0,99 menunjukkan bahwa kinerja model stabil di kedua kelas, baik secara rata-rata maupun berdasarkan proporsi data. Dengan distribusi data uji yang seimbang, yaitu 500 data untuk masing-masing kelas, hasil ini memperlihatkan bahwa *Bidirectional Long Short Term Memory* mampu melakukan klasifikasi secara optimal tanpa bias terhadap salah satu kategori.

Tabel 8. *Confusion Matrix Bidirectional Long Short Term Memory*

	True Positif (TP)	False Negative (FN)
Actual Non-Hoaks	493	7
Actual Hoaks	6	494

Tabel 8 menunjukkan performa klasifikasi model *Bidirectional Long Short Term Memory* dalam membedakan berita hoaks dan non-hoaks. Dengan jumlah prediksi benar yang tinggi dan kesalahan yang rendah, tabel ini memperlihatkan bahwa *Bidirectional Long Short Term Memory* memiliki presisi dan sensitivitas yang sangat baik.



Gambar 6. Confusion Matrix Bidirectional Long Short Term Memory

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% = \frac{493+497}{493+497+7+6} \times 100\% = \frac{990}{1003} \times 100\% = 0.9870$$

$$Presisi = \frac{TP}{TP+FP} \times 100\% = \frac{493}{493+6} \times 100\% = \frac{493}{499} \times 100\% = 0.9879$$

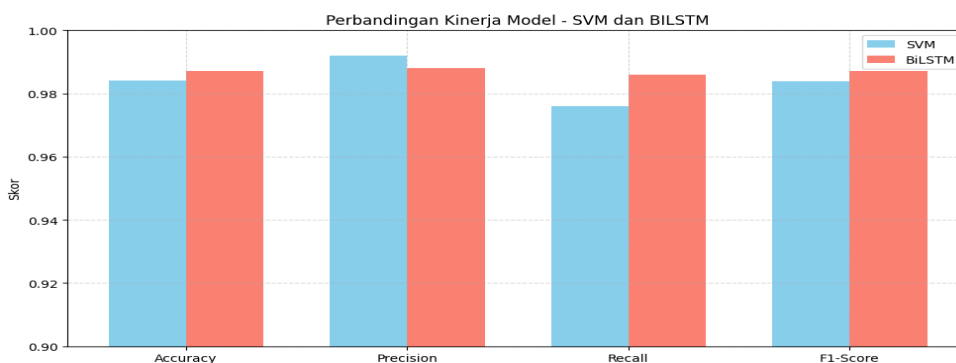
$$Recall = \frac{TP}{TP+FN} \times 100\% = \frac{493}{493+7} \times 100\% = \frac{493}{500} \times 100\% = 0.986$$

$$F1 - Score = 2 \times \frac{precision \times recall}{precision+recall} = 2 \times \frac{0.9879 \times 0.986}{0.9876+0.986} = 2 \times \frac{0.9740}{1.9739} = 0.9868$$

Berdasarkan Gambar 6 *confusion matrix*, model berhasil mengklasifikasikan 494 data non-hoaks dan 493 data hoaks dengan tepat. Kesalahan klasifikasi hanya terjadi pada 6 data non-hoaks yang dikira hoaks (*false positive*), dan 7 data hoaks yang dikira non-hoaks (*false negative*). Secara keseluruhan, akurasi model mencapai 98%, dengan nilai *precision*, *recall*, dan *f1-score* pada kedua kategori kelas baik hoaks maupun non-hoaks masing-masing berada di angka 0,99. Hal ini menunjukkan bahwa model sangat efektif dan konsisten dalam mengenali serta membedakan berita hoaks dari non-hoaks. Dengan hasil yang tinggi dan seimbang pada kedua kelas, model *Bidirectional Long Short Term Memory* ini terbukti handal dan dapat dijadikan dasar dalam pengembangan sistem deteksi berita hoaks yang lebih luas dan otomatis.

3.5 Perbandingan Hasil Prngujian

Dalam penelitian ini, digunakan dua pendekatan algoritma untuk mendeteksi berita hoaks, yaitu *Support Vector Machine* dan *Bidirectional Long Short-Term Memory*. Kedua model tersebut diuji dengan dataset yang terdiri dari 5.000 data berita, yang telah dibagi menjadi 80% untuk pelatihan (4.000 data) dan 20% untuk pengujian (1.000 data). Tujuan dari pengujian ini adalah untuk mengetahui sejauh mana kedua algoritma mampu membedakan berita yang termasuk kategori hoaks dan non-hoaks.



Gambar 7. Perbandingan Hasil Pengujian Model SVM dan BILSTM

Hasil pengujian pada Gambar 7 menunjukkan bahwa *Bidirectional Long Short Term Memory* unggul secara keseluruhan dibandingkan *Support Vector Machine*. *Bidirectional Long Short Term Memory* mampu mencapai akurasi 98%, dengan *precision*, *recall*, dan *f1-score* masing-masing sebesar 0,99 untuk kedua kelas (hoaks dan non-hoaks). Artinya, model ini tidak hanya tepat dalam memprediksi, tetapi juga konsisten dalam mengenali pola pada kedua jenis berita. Sementara itu, *Support Vector Machine* juga menunjukkan performa yang baik, dengan nilai akurasi sekitar 98,4%. Model ini juga cukup presisi dan sensitif terhadap data, terutama pada kategori non-hoaks. Namun, dibandingkan dengan *Bidirectional Long Short Term Memory*, *Support Vector Machine* sedikit tertinggal dalam hal

keseimbangan antara pengenalan berita hoaks dan non-hoaks, serta jumlah kesalahan klasifikasi yang sedikit lebih tinggi. Secara umum, *Bidirectional Long Short Term Memory* lebih unggul karena mampu mempelajari konteks kata dalam kalimat dengan lebih dalam, sehingga dapat mengenali ciri-ciri teks hoaks secara lebih akurat. Sementara itu, *Support Vector Machine* tetap menjadi pilihan yang solid karena proses pelatihannya lebih cepat dan lebih sederhana dari sisi komputasi. Dengan demikian, pemilihan algoritma tergantung pada kebutuhan sistem, apakah lebih mengutamakan akurasi tinggi atau efisiensi dalam pelatihan model.

Tabel 9. Hasil Perbandingan Evaluasi Model SVM dan BiLSTM

Model	Accuracy	Precision	Recall	F1-Score
SVM	0.984	0.9918	0.976	0.9837
BiLSTM	0.9852	0.9879	0.9860	0.9869

Berdasarkan Tabel 9 hasil evaluasi menunjukkan bahwa kedua model, *Support Vector Machine* dan *Bidirectional Long Short Term Memory*, memiliki kinerja yang sangat baik dalam klasifikasi berita hoaks. *Bidirectional Long Short Term Memory* unggul dalam akurasi (0,9852), *recall* (0,9860), dan *F1-Score* (0,9869), sedangkan *Support Vector Machine* memiliki nilai *precision* yang lebih tinggi (0,9918). Dengan demikian, *Bidirectional Long Short Term Memory* menunjukkan performa yang lebih seimbang dan efektif secara keseluruhan dalam mendeteksi berita hoaks.

Tabel 10. Hasil Perbandingan *Confusion Matrix*

Model	True Positive (TP)	True Negative (TN)	False Positive (FP)	False Negative (FN)	Jumlah Data
SVM	488	496	4	12	1.000
BiLSTM	493	497	6	7	1.000

Berdasarkan Tabel 10, model *Bidirectional Long Short Term Memory* menghasilkan lebih banyak prediksi benar (TP dan TN) dibandingkan *Support Vector Machine*, serta memiliki jumlah *false negative* (FN) yang lebih sedikit, yaitu 7 dibandingkan 12. Hal ini menunjukkan bahwa *Bidirectional Long Short Term Memory* lebih mampu mengenali berita hoaks dengan lebih akurat, meskipun *false positive*-nya sedikit lebih tinggi. Secara keseluruhan, *Bidirectional Long Short Term Memory* menunjukkan kinerja yang lebih baik dalam mendeteksi berita hoaks.

4. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan performa dua algoritma machine learning, yaitu *Support Vector Machine* dan *Bi-Directional Long Short Term Memory*, dalam mengklasifikasikan berita hoaks berbahasa Indonesia. Berdasarkan hasil pengujian terhadap 5.000 data, yang dibagi menjadi 4.000 data latih dan 1.000 data uji, kedua algoritma sama-sama menunjukkan kinerja yang baik. Namun, *Bi-Directional Long Short Term Memory* menunjukkan performa yang lebih unggul dibandingkan *Support Vector Machine*. Model *Bidirectional Long Short Term Memory* berhasil mencapai akurasi hingga 99% dengan *precision*, *recall*, dan *f1-score* sebesar 0,99 untuk kedua kelas, menunjukkan bahwa model ini sangat andal dan konsisten dalam mendeteksi berita hoaks dan non-hoaks. Sementara itu, model *Support Vector Machine* mencatatkan akurasi 98,46%, dengan metrik evaluasi yang juga tinggi namun sedikit lebih rendah dibandingkan *Bidirectional Long Short Term Memory*. Perbedaan performa ini menunjukkan bahwa pendekatan deep learning seperti *Bi-Directional Long Short Term Memory* memiliki keunggulan dalam mengenali pola dan konteks bahasa secara lebih mendalam dibandingkan dengan algoritma klasifikasi tradisional seperti *Support Vector Machine*. Namun, perlu dicatat bahwa *Bi-Directional Long Short Term Memory* membutuhkan sumber daya komputasi yang lebih besar dan waktu pelatihan yang lebih lama dibandingkan *Support Vector Machine*, yang lebih ringan dan lebih cepat diproses. Keterbatasan dalam penelitian ini antara lain terletak pada ketersediaan data yang terbatas dari satu sumber dan belum dieksplorasi fitur-fitur tambahan seperti konteks temporal atau metadata berita. Oleh karena itu, untuk penelitian selanjutnya, disarankan untuk menggunakan dataset yang lebih bervariasi dan representatif, serta menguji algoritma lain yang belum dibahas, termasuk metode ensemble atau arsitektur deep learning yang lebih kompleks. Dengan demikian, diharapkan penelitian selanjutnya dapat memberikan hasil yang lebih akurat dan mampu meningkatkan keandalan sistem deteksi berita hoaks secara otomatis di masa mendatang.

REFERENCES

- [1] T. A. Roshinta, E. Kumala, and I. F. Dinata, "Sistem Deteksi Berita Hoax Berbahasa Indonesia Bidang Kesehatan," *Remik Ris. dan E-Jurnal Manaj. Inform. Komput.*, vol. 7, no. 2, pp. 1167–1173, 2023, doi: 10.33395/remik.v7i2.12369.
- [2] R. Dickiprabowo, I. Widaningrum, and J. Karaman, "Sistem Deteksi Berita Hoax Pemilu 2024 Indonesia Menggunakan Algoritma KNN Dan SVM Indonesian 2024 Election Hoax News Detection System Using KNN And SVM Algorithm," *JIKO*, vol.9, no. 1, pp. 93–111, 2025, doi: 10.26798/jiko.v9i1.1424.
- [3] M. Frananda Adiezwar Ramadhan, I. Rizal Setiawan, and A. Asriyanik, "Klasifikasi Hoax Dan Fakta Menggunakan Algoritma Shallow Neural Network Pada Berita Politik Pemilihan Presiden Indonesia 2024," *JATI (Jurnal Mhs. Tek. Inform.*,



- vol. 8, no. 4, pp. 8006–8013, 2024, doi: 10.36040/jati.v8i4.10621.
- [4] I. P. P. Panji Bintoro, Ratnasari, Edy Wihardjo and A. Asari, *Pengantar Machine Learning*. Malang: Pt Mafy Media Literasi Indonesia, 2024. [Online]. Available: <https://repository.um.ac.id/5619/1/fullteks.pdf>
- [5] E. S. Eriana and D. A. Zein, *Artificial Intelligence*, Purbalingga: Eureka Media Aksara, 2023rd ed
- [6] I. Sulistyowati and Jamaaluddin, *Buku Ajar Mata Kuliah Kecerdasan Buatan (Artificial Intelligence)*, Juli, 2021. Sidoarjo: UMSIDA PRESS Jl., 2021. [Online]. Available: <https://press.umsida.ac.id/index.php/umsidapress/article/view/978-623-6292-25-9>
- [7] A. Zahra and M. N. Fauzan, “Sistem Identifikasi ‘Fake News’ menggunakan Metode Multinomial Naïve Bayes,” *J. Sist. dan Teknol. Inf.*, vol. 10, no. 4, p. 489, 2022, doi: 10.26418/justin.v10i4.52441.
- [8] A. Awalina, F. A. Bachtiar, and I. Indriati, “Klasifikasi Ulasan Palsu Menggunakan Borderline Over Sampling (BOS) dan Support Vector Machine (SVM) (Studi Kasus : Ulasan Tempat Makan),” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 2, pp. 419–426, 2022, doi: 10.25126/jtiik.2022925692.
- [9] M. N. Raza, “Sistem Deteksi Berita Hoax Menggunakan Algoritma Naïve 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>
- [10] M. F. Muttaqin, T. Bukhori, Y. Yanto, N. Agustina, and M. Naseer, “Sistem Prediksi Berita Palsu Tentang Virus Covid-19 Menggunakan Algoritma Support Vector Machine (Svm),” *Naratif J. Nas. Riset, Apl. dan Tek. Inform.*, vol. 5, no. 1, pp. 26–33, 2023, doi: 10.53580/naratif.v5i1.187.
- [11] P. Ayuningtyas and H. Tantyoko, “Perbandingan Metode Word2vec Model Skipgram pada Ulasan Aplikasi Linkaja menggunakan Algoritma Bidirectional LSTM dan Support Vector Machine,” *JUSTIN (Jurnal Sist. dan Teknol. Informasi)*, vol. 12, no. 1, pp. 189–196, 2024, doi: 10.26418/justin.v12i1.72530.
- [12] M. R. R. H. G. Rizqullah, “Indonesian Fact and Hoax Political News.” <https://www.kaggle.com/datasets/linkgish/indonesian-fact-and-hoax-political-news>, Access Date 10 April 2025
- [13] M. N. Nugraha and M. Arrofiq, “Purwarupa Sistem Klasifikasi Legalitas Investasi Berbasis Algoritma Bidirectional Long Short Term Memory,” *J. Internet Softw. Eng.*, vol. 5, no. 1, pp. 9–14, 2024, doi: 10.22146/jise.v5i1.8938.
- [14] ramadhan andi, “_Tampilan Komparasi Algoritma Neural Network dan K-Nearest Neighbor Dalam Mendeteksi Malware Android[1].pdf,” *Build. Informatics, Technol. Sci.*, vol. 5, No 1, J, pp. 191–199, 2023, doi: 10.47065/bits.v5i1.3538.
- [15] M. R. Sudrajat and M. Zakariyah, “Penerapan Natural Language Processing dan Machine Learning untuk Prediksi Stres Siswa SMA Berdasarkan Analisis Teks,” *Build. Informatics, Technol. Sci.*, vol. 6, no. 3, 2024, doi: 10.47065/bits.v6i3.6180.
- [16] B. Wicaksono, V. Rahmayanti, and S. Nastiti, “Analisis Sentimen dalam Opini Publik di Chanel Youtube Indonesia Lawyers Club Tentang Isu Populer dengan Menggunakan Metode LSTM dan Bi-LSTM,” *J. Algoritm.*, vol. Vol. 22 No, pp. 241–251, 2024, doi: 10.33364/algoritma/v.21-2.1696.
- [17] Y. Ardiansah, S. Monalisa, and F. Muttakin, “Analisis Sentimen Komentar Perplexity AI di X Tentang Pendidikan Menggunakan Support Vector Machine,” *Build. Informatics, Technol. Sci.*, vol. 6, no. 3, pp. 2015–2023, 2024, doi: 10.47065/bits.v6i3.6396.
- [18] I. Cholissodin and A. A. Soebroto, *Ai , Machine Learning & Deep Learning (Teori & Implementasi)*, 19 Juli 20., no. July 2019. Malan: UB FILKOM, 2021. [Online]. Available: link: <http://bit.ly/3piOnnU>
- [19] I. R. Fatmawati, M. Pajar, and K. Putra, “Optimasi Analisis Sentimen Twitter Tentang Isu Kesehatan Mental dengan Bi-LSTM pada Dataset Tidak Berimbang,” *Build. Informatics, Technol. Sci.*, vol. 6, no. 4, pp. 2424–2435, 2025, doi: 10.47065/bits.v6i4.6890.
- [20] D. Setyadin, R. H. Winasis, and G. Triyono, “Deteksi Berita Palsu menggunakan Algoritma Random Forest Fake News Detection using the Random Forest Algorithm,” *Sist. J. Sist. Inf.*, vol. 14, pp. 1142–1153, 2025, doi: DOI: <https://doi.org/10.32520/stmsi.v14i3.4995>.