

Fake News Detection : Memberdayakan Partisipasi Publik Melalui Informasi yang Akurat dengan Deteksi Berita Palsu Menggunakan Model Neural Network

Fehru Mandala Putra, Muhammad Faishal Makarim, Muhammad Tsaqif

Fakultas Sains dan Analitika Data, Institut Teknologi Sepuluh Nopember

Abstrak

Penyebaran berita hoax secara luas di media sosial telah menjadi tantangan serius dalam hal informasi yang akurat dan berkepentingan publik. Dalam penelitian ini, kami memperkenalkan pendekatan menggunakan model Deep Learning untuk deteksi otomatis berita hoax. Kami mengusulkan penggunaan arsitektur naive bayes, jaringan saraf feedforward, jaringan saraf konvolusi (CNN) dan jaringan saraf rekurensi (RNN) untuk mengekstraksi fitur penting dari teks dan memahami konteks yang lebih luas dalam berita. Metode ini menggabungkan 3 jenis embedding (token, karakter, fitur) untuk mendapat konteks dan pola lebih dalam dalam teks berita. Pendekatan kami melibatkan langkah-langkah berikut: pertama, kami mengumpulkan dataset dari penelitian sebelumnya dan media pemberitaan terkenal kemudian diklasifikasikan menjadi dua kategori: berita asli dan berita hoax. Kemudian, kami melatih model Deep Learning menggunakan data pelatihan yang dilabeli untuk mengenali pola dan karakteristik yang membedakan antara berita asli dan hoax. Selanjutnya, kami menguji kinerja model dengan menggunakan dataset pengujian independen dan menerapkan metrik evaluasi standar seperti akurasi, presisi, recall, dan F1-score. Hasil percobaan kami menunjukkan bahwa model Deep Learning yang diusulkan dapat mencapai kinerja yang baik dalam mendeteksi berita hoax. Dengan akurasi, presisi, recall, dan F1-score yang jika dirata-ratakan sekitar 96 % dan metrik tertinggi ada pada model Tribrid Multimodal Embedding dengan akurasi jika dibulatkan sebesar 97 %, pendekatan ini menunjukkan potensi model ini untuk digunakan dalam sistem deteksi otomatis berita hoax di platform media sosial dan situs berita. Implikasi dari penelitian ini adalah pengembangan solusi teknologi yang efektif dan efisien untuk mengurangi dampak negatif penyebaran berita hoax dan mempromosikan informasi yang akurat dan berkepentingan publik.

Kata kunci: *Fake News Detection, Deep Learning, Natural Language Processing*

1. Pendahuluan

Dalam era digital yang semakin maju, akses terhadap informasi menjadi lebih mudah dan cepat. Namun, di tengah kemudahan tersebut, penyebaran berita palsu atau *fake news* menjadi semakin merajalela. *Fake news* memiliki potensi merugikan masyarakat dan lembaga dengan menyebarkan informasi yang salah, menyesatkan, dan menghasut. Penyebaran *fake news* dalam lingkungan digital telah menjadi permasalahan serius yang mempengaruhi kehidupan masyarakat secara luas. Berbagai platform media sosial dan situs berita tidak terverifikasi telah menjadi wadah bagi penyebaran informasi palsu yang menyesatkan. Dampak negatif dari *fake news* tidak hanya terbatas pada ketidaktepatan informasi, tetapi juga dapat menimbulkan ketegangan sosial dan konflik

antarkelompok. Keberadaan *fake news* dalam berbagai konteks, seperti sosial, ekonomi, politik, dan kesehatan, dapat mempengaruhi persepsi publik dan merusak kepercayaan terhadap media dan institusi. Ketika informasi yang akurat dan dapat dipercaya sulit dibedakan dari *fake news*, masyarakat menjadi rentan terhadap manipulasi dan penipuan. Selain itu, keberadaan *fake news* juga dapat menghancurkan kepercayaan terhadap media dan institusi, yang merupakan fondasi penting dalam sebuah negara demokratis.

Penyebaran *fake news* juga memiliki dampak yang signifikan dalam konteks pembangunan manusia berkelanjutan. Partisipasi publik yang aktif dan informasi yang akurat adalah faktor kunci dalam membangun sumber daya manusia yang maju. Namun, penyebaran *fake news* dapat menjadi hambatan dalam mencapai partisipasi yang optimal, karena informasi yang palsu dapat mempengaruhi persepsi dan keputusan masyarakat. Untuk mencapai pembangunan yang berkelanjutan, diperlukan upaya untuk mengurangi dampak negatif *fake news* melalui pengembangan metode dan teknologi deteksi *fake news* yang efektif. Dalam konteks Indonesia, penyebaran *fake news* menjadi tantangan yang semakin mendesak. Sebagai negara dengan populasi yang besar dan tingkat penetrasi internet yang tinggi, masyarakat Indonesia sangat rentan terhadap penyebaran *fake news*. Hal ini dapat mempengaruhi stabilitas sosial, perkembangan ekonomi, dan keberlanjutan politik.

Oleh karena itu, penelitian ini dilakukan dengan tujuan untuk mengembangkan metode dan teknologi yang dapat mendeteksi *fake news* secara efektif dalam konteks Indonesia. Dengan mengidentifikasi karakteristik dan pola yang khas dari *fake news* yang menyebar di Indonesia, diharapkan dapat dibangun sistem deteksi yang dapat mengenali penyebaran informasi palsu dengan akurasi tinggi. Dengan demikian, penelitian ini bertujuan untuk memberikan kontribusi dalam membangun sumber daya manusia Indonesia yang maju dan berkelanjutan melalui pengembangan mekanisme *fake news detection* yang handal dan efektif.

2. Penelitian Terkait

Penelitian pertama pada tahun 2017 dilakukan oleh Agung dkk dari jurusan teknik komputer UNDIP yang berkolaborasi Yosua dkk dari jurusan teknik elektro UNDIP yang berjudul “Hoax Detection System on Indonesian News Sites Based on Text Classification using SVM and SGD”[1]. Mereka melakukan *Web Scraping* dari suatu situs untuk mengekstrak kontennya menggunakan *Web Crawler* yang terdiri dari 680 halaman, diantaranya terdapat 180 berita hoax dan 500 berita asli. Penelitian ini menggunakan algoritma pembelajaran mesin *supervised learning* seperti SVM dan SGD. Penelitian ini juga menggunakan ekstraksi fitur seperti TF-IDF. Hasil akurasi menggunakan SVM mencapai 80% dan mereka turut menyimpulkan bahwa menggunakan SGD dengan kernel modified-huber meningkatkan akurasi dan presisi SVM sekitar 4% dan 20% secara berturut-turut serta Akurasi dari TF-IDF lebih baik dikombinasikan dengan SGD ketika sampel klasifikasi hoax tidak memiliki istilah khusus, tetapi memiliki pola unik pada portal berita yang sama.

Lalu penelitian selanjutnya dilakukan oleh Angga dan Metty pada tahun 2020 yang berjudul “Implementasi Deep Learning Menggunakan Metode CNN dan LSTM untuk Menentukan Berita Palsu dalam Bahasa Indonesia”[2]. Penelitian ini menggunakan teknik *Deep Learning* dalam menentukan berita palsu dan berita fakta. Data yang diambil melalui proses *Web Scraping* dari situs [TurnbackHoax.id](https://turnbackhoax.id) dan memperoleh 1786 berita yang terdiri dari 802 berita fakta dan 984 berita palsu. Penelitian terdiri dari beberapa tahap yaitu pengumpulan data, labeling data, preprocessing data, word embedding, splitting data proses pembentukan model, evaluasi, pengujian data input baru dan perbandingan evaluasi dari model yang sudah terbentuk. Mereka menggunakan 2 model yaitu CNN dan *Long Short Term Memory* (LSTM). Setelah dilakukan pemodelan, mereka mendapati bahwa tingkat akurasi menggunakan model CNN sebesar 88% dan tingkat akurasi menggunakan model LSTM sebesar 84% dan penelitian ini mengambil kesimpulan bahwa model CNN dan LSTM cocok

untuk mengidentifikasi berita palsu namun dari segi tingkat akurasi model CNN memiliki tingkat akurasi yang lebih tinggi.

Penelitian lain yang kami baca adalah penelitian yang terjadi pada tahun 2020 oleh Heru Agus Santoso dkk yang berjudul "Fake Twitter Account Classification of Fake News Spreading Using Naïve Bayes"[3]. Penelitian ini menggunakan data hasil *Web Scraping* dari situs [TurnBackHoax.com](https://turnbackhoax.com) dan [Cekfakta.com](https://cekfakta.com). Lalu mencari berita di *Twitter* sekaligus mencari akun penyebar berita palsu dan telah didapat 210 akun yang menyebarkan berita palsu. Penelitian ini menggunakan algoritma pembelajaran mesin yaitu *Naive Bayes*. Selain itu, penelitian ini juga menggunakan 9 parameter untuk menentukan akun palsu dan akun asli diantaranya Profil Dibuat, Jumlah Favorit, Jumlah Pengikut, Jumlah yang Diikuti, Geo Aktif, Tingkat Pengikut, Tingkat yang Diikuti, Rasio Pengikut yang Diikuti, dan Terverifikasi. Dalam prosesnya, penelitian ini juga membagi kedalam 2 jenis data yaitu *Data Training* dan *Data Testing*. Hasil Akurasi yang diperoleh sebesar 80%.

3. Kajian Pustaka

3.1 Pengambilan Data (Web Scraping)

Web Scraping adalah proses pengumpulan data web terstruktur yang dilakukan secara otomatis dengan menggunakan aplikasi atau kode pemrograman khusus. Data yang dikumpulkan dapat berasal dari ribuan, jutaan, bahkan milyaran data yang terpampang di dunia maya. Proses automasi ini dapat dikustomisasi sesuai dengan data yang dibutuhkan sehingga dapat meminimalisir informasi yang tidak perlu sistem web scraping pada dasarnya sangat sederhana, yaitu terdiri atas dua bagian: web crawler dan web scraper. Ibarat jejaring dunia maya, web crawler adalah 'laba-laba' dengan kecerdasan buatan (AI) yang bergerak menelusuri internet untuk mencari informasi dalam suatu URL. Sementara itu, web scraper adalah alat yang digunakan untuk mengekstrak data dari URL yang sebelumnya ditelusuri oleh crawler. Scraper didesain secara kompleks, tergantung informasi yang harus diekstrak [4].

3.1 Pra Pemrosesan data (Text Processing)

Text Processing adalah sebuah pemrosesan teks untuk menghasilkan informasi atau insights dari sebuah data. Salah satu metode yang paling sering digunakan dalam Text Processing adalah Natural Language Processing (NLP) [5]. Proses NLP meliputi:

- **Case Folding**
Proses dalam text preprocessing yang dilakukan untuk menyeragamkan karakter pada data. Proses case folding adalah proses mengubah seluruh huruf menjadi huruf kecil. Pada proses ini karakter-karakter 'A'-'Z' yang terdapat pada data diubah kedalam karakter 'a'-'z' [6].
- **Stemming**
Suatu teknik pencarian bentuk dasar dari suatu term. Yang dimaksud dengan term itu sendiri adalah tiap kata yang berada pada suatu dokumen teks. Stemming dilakukan pada saat pembuatan indeks dari suatu dokumen. Pembuatan indeks dilakukan karena suatu dokumen tidak dapat dikenali langsung oleh suatu sistem temu kembali informasi atau information retrieval (IR) sistem. Oleh karena itu, dokumen tersebut terlebih dahulu perlu dipetakan ke dalam suatu representasi dengan menggunakan teks yang berada di dalamnya [7].
- **Removing Stopwords**
Proses pembuangan term yang tidak memiliki arti atau tidak relevan. Term yang diperoleh dari tahap tokenisasi dicek dalam suatu daftar stopwords, apabila sebuah kata masuk di dalam daftar stopwords maka kata tersebut tidak akan diproses lebih lanjut. Sebaliknya apabila sebuah kata tidak termasuk di dalam daftar stopwords maka kata tersebut akan masuk keproses berikutnya [8].

- Removing Punctuation
Proses dimana sistem akan menghilangkan tanda baca atau simbol yang ada dalam dataset. Tanda baca atau simbol ini dihapus karena tidak berpengaruh pada hasil akhir.
- Feature Extraction
Teknik pengambilan ciri / feature dari suatu bentuk yang nantinya nilai yang didapatkan akan dianalisis untuk proses selanjutnya.

3.2 Transformasi data (Word Embedding)

Suatu proses mengubah data sehingga data siap untuk dianalisis.

3.2.1 Tf-Idf Vectorizer

Term Frequency merupakan frekuensi kemunculan term i pada dokumen j dibagi dengan total term pada dokumen j . Ditulis dalam bentuk,

$$tf_{ij} = \frac{f_d(i)}{\max_{j \in d} f_d(j)}$$

IDF berfungsi mengurangi bobot suatu term jika kemunculannya banyak tersebar diseluruh dokumen, dituliskan dalam bentuk,

$$idf(t, D) = \log \frac{N}{|\{d \in D : t \in d\}|}$$

N adalah jumlah total document dalam corpus, $N = |D|$.

$|\{d \in D : t \in d\}| = df(t)$, adalah jumlah dokumen yang mengandung term t . IDF juga dapat dituliskan dalam bentuk,

$$idf(t, D) = \log \left(\frac{N}{df(t) + 1} \right)$$

Penambahan 1 untuk menghindari pembagian terhadap 0 jika $df(t)$ tidak ditemukan pada corpus. Nah, dari dictionary TF dan IDF kita dapat menentukan TF-IDF dengan mengalikan kedua dictionary tersebut value by value dan simpan ke dalam Pandas Series [9].

3.2.2 Word Embedding

Word embeddings adalah representasi terdistribusi untuk teks yang mungkin merupakan salah satu terobosan kunci untuk kinerja yang mengesankan dari metode pembelajaran mendalam pada masalah pemrosesan bahasa alami yang menantang. Istilah embeddings, kata sebenarnya adalah kelas teknik di mana kata-kata individual direpresentasikan sebagai vektor bernilai nyata dalam ruang vektor yang telah ditentukan. Setiap kata dipetakan ke satu vektor dan nilai-nilai vektor dipelajari dengan cara yang menyerupai jaringan saraf dalam Artificial Intelligence atau yang sering dikenal dengan kecerdasan buatan, dan karenanya teknik ini sering disamakan dengan bidang pembelajaran yang mendalam [10].

3.2.3 Character Embedding

Character Embedding adalah Teknik pemetaan karakter ke dalam ruang vektor kontinu. Ini adalah metode yang umum digunakan dalam pemrosesan bahasa alami (Natural Language Processing, NLP) untuk merepresentasikan kata-kata atau teks berbasis karakter dalam bentuk yang dapat dipahami oleh model pembelajaran mesin.

3.2.4 Feature Embedding

Feature Embedding Proses merepresentasikan fitur atau atribut data dalam dimensi yang lebih rendah sambil mempertahankan makna atau informasi penting. Tujuannya adalah untuk mengonversi data besar dan berpotensi jarang menjadi representasi yang lebih ringkas dan bermakna. Penyematan fitur umumnya digunakan untuk merepresentasikan data tekstual seperti kata, kalimat atau dokumen dalam bentuk numerik yang dapat dipahami oleh algoritma pembelajaran mesin. Representasi numerik ini memungkinkan algoritme untuk memproses dan menganalisis data teks secara efisien.

3.3 Pemodelan (Modelling)

Pemodelan adalah Proses menciptakan representasi visual atau cetak biru yang menentukan pengumpulan informasi dan sistem manajemen berbagai organisasi. Cetak biru atau model data ini membantu berbagai pemangku kepentingan, seperti analis, ilmuwan, dan perekayasa data untuk menciptakan pandangan terpadu mengenai data organisasi. Model tersebut menguraikan data yang dikumpulkan oleh bisnis, hubungan antara berbagai set data, dan metode yang akan digunakan untuk menyimpan serta menganalisis data.

3.3.1 Multinomial Naive Bayes

MNB adalah model probabilistik yang menggunakan jumlah absolut dan memprediksi label dalam dataset dengan mengenali frekuensi kata tertentu dalam dokumen teks[11]. Tanpa memperhitungkan relasi antar kata MNB mengklasifikasikan data teks hanya dari frekuensi kata yang ada. MNB biasanya bekerja bagus dengan dengan menggunakan TF-IDF Vectorizer.

$$P(A | B) = \frac{P(B | A) \cdot P(A)}{P(B)}$$

A, B = events
 $P(A|B)$ = probability of A given B is true
 $P(B|A)$ = probability of B given A is true
 $P(A), P(B)$ = the independent probabilities of A and B

Gambar 3.1 Algoritma Multinomial Naive Bayes

3.3.2 Feed Forward Neural Network (FFNN)

Feed Forward Neural Network merupakan metode non-parametrik yang dapat digunakan untuk melakukan prediksi dari data time series tanpa harus terikat dengan asumsi klasik[12]. Jadi jaringan saraf buatan ini mengalirkan informasi dari input ke output tanpa ada feedback loop. FFNN terdiri atas beberapa lapisan neuron yang terhubung secara sekuensial, dimana setiap neuron pada lapisan tertentu menerima input dari neuron pada lapisan sebelumnya dan mengirimkan output ke neuron pada lapisan berikutnya. FFNN digunakan untuk mempelajari pola pada data input dan menghasilkan output yang sesuai dengan pola tersebut.

```

Model: "model_1_dense"
-----
Layer (type)                Output Shape                Param #
-----
input_73 (InputLayer)       [(None, 1)]                 0
text_vectorization_8 (TextV  (None, 203)                 0
ectorization)
embedding (Embedding)       (None, 203, 128)           6400000
global_max_pooling1d_48 (Gl  (None, 128)                 0
obalMaxPooling1D)
dense_114 (Dense)           (None, 64)                  8256
dense_115 (Dense)           (None, 16)                  1040
dense_116 (Dense)           (None, 1)                   17
-----
Total params: 6,409,313
Trainable params: 6,409,313
Non-trainable params: 0

```

Gambar 3.2 Arsitektur lapisan FFNN

3.3.3 Bidirectional Long Short Term Memory (Bi-LSTM)

Bidirectional LSTM, atau biLSTM, adalah model pemrosesan urutan yang terdiri dari dua LSTM: satu mengambil input ke arah depan, dan yang lainnya ke arah belakang. BiLSTM secara efektif meningkatkan jumlah informasi yang tersedia untuk jaringan, meningkatkan konteks yang

tersedia untuk algoritma (misalnya, mengetahui kata apa yang segera mengikuti dan mendahului sebuah kata dalam sebuah kalimat)[13].

```

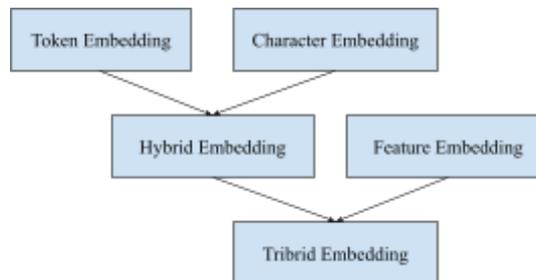
Model: "model_1_dense"
-----
Layer (type)                Output Shape                Param #
-----
input_73 (InputLayer)       [(None, 1)]                 0
text_vectorization_8 (TextV  (None, 203)                 0
ectorization)
embedding (Embedding)       (None, 203, 128)           6400000
global_max_pooling1d_48 (Gl  (None, 128)                 0
obalMaxPooling1D)
dense_114 (Dense)           (None, 64)                  8256
dense_115 (Dense)           (None, 16)                  1040
dense_116 (Dense)           (None, 1)                   17
-----
Total params: 6,409,313
Trainable params: 6,409,313
Non-trainable params: 0

```

Gambar 3.3 Arsitektur lapisan Bi-LSTM

3.3.6 Tribrid Multimodal Embedding

Tribrid Multimodal Embedding adalah model pembelajaran data sekuensial yang menggunakan 3 input numerik sebagai masukannya token embedding, character embedding, dan feature embedding. Dengan arsitektur convolutional 1 dimensions, model ini memaksimalkan pencarian pola dan makna secara dalam dalam sebuah data teks.



Gambar 3.4 Arsitektur Tribrid Embedding bekerja

3.4 Evaluasi Metrik (Metrics Evaluation)

- Accuracy

Accuracy Merupakan rasio prediksi Benar (positif dan negatif) dengan keseluruhan data. Akurasi menjawab pertanyaan “Berapa persen mahasiswa yang benar diprediksi DO dan Tidak DO dari keseluruhan mahasiswa”.

$$\text{Akurasi} = (TP + TN) / (TP+FP+FN+TN)$$

- Precision

Precision Merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif. Precision menjawab pertanyaan “Berapa persen mahasiswa yang benar DO dari keseluruhan mahasiswa yang diprediksi DO?”.

$$\text{Precision} = (TP) / (TP+FP)$$

- Recall

Recall Merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif. Recall menjawab pertanyaan “Berapa persen mahasiswa yang diprediksi DO dibandingkan keseluruhan mahasiswa yang sebenarnya DO”.

$$\text{Recall} = (TP) / (TP + FN)$$

- F1-Score

F1 Score merupakan perbandingan rata-rata presisi dan recall yang dibobotkan

$$\text{F1 Score} = 2 * (\text{Recall} * \text{Precision}) / (\text{Recall} + \text{Precision}).$$

4. Metode Penelitian

4.1 Ekstraksi Data dari Internet

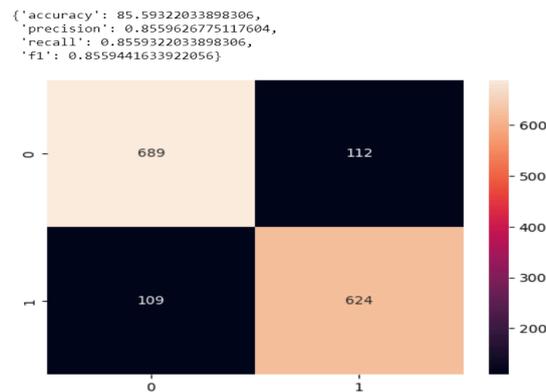
early stopping untuk menghentikan proses pembelajaran jika validation accuracy tidak naik lagi dan model checkpoint untuk mengambil weight matrix dari epochs dengan validation accuracy tertinggi. Model akan diulang-ulang pada fitting data train dengan random state yang berbeda.

```
Model: "model_3_bi-lstm"
-----
Layer (type)                   Output Shape          Param #
-----
input_33 (InputLayer)          [(None, 1)]           0
text_vectorization_4 (TextV    (None, 203)           0
ectorization)
embedding_3 (Embedding)        (None, 203, 128)     6400000
bidirectional_4 (Bidirectio    (None, 203, 128)     98816
nal)
global_max_pooling1d_24 (Gl    (None, 128)           0
obalMaxPooling1D)
dropout_27 (Dropout)           (None, 128)           0
dense_53 (Dense)                (None, 32)            4128
dense_54 (Dense)                (None, 1)             33
-----
Total params: 6,502,977
Trainable params: 6,502,977
Non-trainable params: 0
-----
```

Gambar 4.4 Contoh Arsitektur Model Pembelajaran

4.4 Evaluasi Metrik

Dari model yang telah diadaptasi dengan data train akan dilakukan evaluasi metrik dari model yang dibuat menggunakan data test. Akan diambil 4 metrik yaitu accuracy, precision, recall, dan f1-score untuk mengetahui keakuratan model pada data asing. Setelahnya dibuat tabel confusion matrix untuk melihat orientasi model dalam memprediksi data teks.

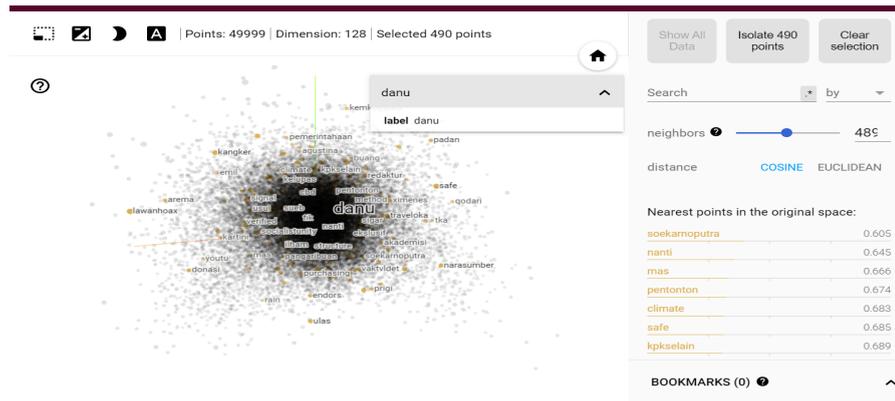


Gambar 4.5 Contoh Metrik dan Confusion Matrix yang akan dibuat

5. Hasil dan Pembahasan

Pada penelitian ini kita menggunakan 5 dataset yang terdiri dari 3 dataset dari penelitian sebelumnya dan 2 dataset scraping dari turbackhoax.id dan news.detik.com. Detail data terdiri dari 3528 data berita benar dan 4141 berita salah dengan jumlah 7669 data. Data selanjutnya dilakukan pra pemrosesan teks sehingga mengurangi panjang teks sekitar 30%. Data dibagi menjadi data train dan data test dengan rasio 80 : 20. Data kemudian dijadikan tensor matriks kata dengan bantuan Text Vectorization dan Embedding dari Tensorflow Library, berikut hasilnya:

```
[',',
 '[UNK]',
 'ada',
 'video',
 'com',
 'laku',
 'indonesia',
 'orang',
 'jakarta',
 'hasil',
 'informasi',
 'akun',
 'rupa',
 'fakta',
 'narasi',
 'salah',
 'foto',
 'www',
 'referensi',
 'baca']
```



(a)

(b)

Gambar 5.1 a, Frekuensi kata yang sering muncul pada data teks.

Gambar 5.1 b, Persebaran vektor kata pada ruang 3 dimensi pada pembelajaran mesin

Data teks juga diekstraksi fitur-fiturnya seperti jumlah kata, jumlah kalimat, jumlah link, dan jumlah angka pada teks yang selanjutnya akan dimasukkan ke model. Selain itu data teks juga akan diubah menjadi tensor matriks karakter guna mengambil lebih banyak makna dan pola pada data teks pada model yang akan kita latih. Berikut fitur data teks:

	text	target	kata	kalimat	angka	link
0	Foto: Kumparan.com Debunk ini berisi iKlarifik...	1	286	31	15	4
1	Foto Ilustrasi Perkosaan Debunk ini berisi kla...	1	168	17	1	1
2	Debunk ini berisi klarifikasi dari PT Ultrajay...	1	306	25	3	3
3	foto: tribunnews.com Debunk ini berisi Klirik...	1	187	23	9	1
4	Foto: tribunnews.com (Jokowi sedang memantau l...	1	192	21	9	4
...
7664	\nJakarta - Polri mewajibkan pembuat SIM harus...	1	208	31	6	0
7665	\nJakarta - Wakil Ketua MPR RI Lestari Moerdij...	1	203	22	6	0
7666	\nJakarta - Sebanyak 19 pelaku Usaha Mikro Kec...	1	445	40	11	0
7667	\nJakarta - Dewan Pengawas (Dewas) KPK menemuk...	1	146	22	5	0
7668	\nJakarta - Seorang pria bernama Rifkho Achmad...	1	271	39	11	0

Gambar 5.2 Dataset yang telah diekstraksi fiturnya

Selanjutnya fitur data teks akan di bagi menjadi beberapa range angka (bins) untuk mengurangi variasi yang terlalu banyak. Kemudian fitur ini akan dilakukan one hot encoding untuk memaksimalkan model dalam belajar dari pola fitur data teks. Melalui berbagai proses ini data telah siap untuk dimasukkan ke model pembelajaran mesin. Model machine learning dan deep learning akan mulai dibuat, detail ada di kajian pustaka.

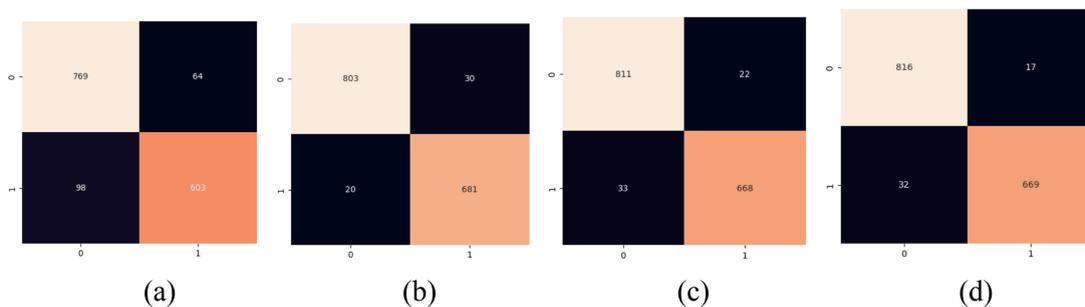
Data train yang sudah di pisah tadi akan digunakan untuk melatih keempat model yang telah dibuat yaitu Multinomial Naive Bayes, Feed Forward Neural Network, Bi-LSTM, dan Tribrid Multimodal Embedding. Pada proses pelatihan data train menggunakan 16 epochs dan callback Early stopping dan Model Checkpoint untuk mengambil model paling akurat dan memberhentikan pembelajaran ketika validation accuracy tidak naik lagi. Proses pelatihan data train akan dilakukan 5 kali dengan random state yang berbeda-beda yaitu 157, 132, 21, 114, dan 158 . Dan dari kelima model dengan random state yang berbeda akan diambil rata-rata pada setiap metrik yaitu accuracy, precision, recall, dan f1-score dengan menggunakan data test yang telah disiapkan sebelumnya. Berikut metrik hasil prediksi data test dari pembelajaran model yang telah dibuat:

Tabel 5.1 Metrik hasil prediksi keempat model pada data test

	Accuracy	Precision	Recall	F1-score
--	----------	-----------	--------	----------

MNB	90,25 %	90,30 %	90,25 %	90,23 %
FFNN	96,24 %	96,25 %	96,24 %	96,24 %
Bi-LSTM	96,15 %	96,16 %	96,15 %	96,15 %
Tribrid Multimodal	96, 58 %	96,61 %	96,58 %	96,58 %

Selain metrik, confusion matrix juga diambil guna mengetahui orientasi model dalam memprediksi target, apakah lebih akurat memprediksi berita benar atau lebih akurat memprediksi berita salah. Berikut adalah confusion matrix dari keempat model.



Gambar 5.3 Confusion matrix, (a) Multinomial Naive Bayes (b) Feed Forward Neural Network, (c) Bidirectional Long Short Term Memory, (d) Tribrid Multimodal Embedding

6. Kesimpulan

Penelitian ini mengusulkan model deep learning untuk solusi penyebaran berita hoax yang semakin meresahkan. Dataset didapat dari penelitian sebelumnya dan scraping dari saluran berita yang ada. Data diproses dengan berbagai teknik pra pemrosesan teks dan diubah jadi bentuk numerik. Dibuat 4 model machine learning dan deep learning untuk klasifikasi teks berita yaitu MNB, FFNN, bi-LSTM, dan Tribrid Embedding. Dari keempat model tersebut didapat akurasi secara berturut-turut 90,25 %, 96,24 %, 96,15 %, dan 96,58 %. Model keempat menjadi model dengan akurasi paling tinggi diantara ketiga model lainnya dan selanjutnya dapat digunakan untuk memprediksi berita palsu pada kehidupan nyata.

7. Daftar Pustaka

- [1] Prasetijo dkk. (2017). "Hoax Detection System on Indonesian News Sites Based on Text Classification using SVM and SGD". Proc. of 2017 4th Int. Conf. on Information Tech., Computer, and Electrical Engineering (ICITACEE), Oct 18-19, 2017, Semarang, Indonesia.
- [2] Angga ,A & Mustikasari,M. (2020). " Implementasi Deep Learning Menggunakan Metode CNN dan LSTM untuk Menentukan Berita Palsu dalam Bahasa Indonesia". Jurnal Informatika Universitas Pamulang. Vol. 5, No. 4, Desember 2020 (544-552).
- [3] Agus,H dkk. (2020). " Fake Twitter Account Classification of Fake News Spreading Using Naïve Bayes". Diambil dari <http://journal.unnes.ac.id/nju/index.php/sji>.
- [4] Web Scraping,Apa Manfaatnya untuk Bisnis?.(2022).Diakses pada 30 Juni 2023 dari <https://algorit.ma/blog/web-scraping-adalah-2022/>.
- [5] Arifah, D. S. (2020). Penerapan Metode Support Vector Machine dalam Mengklasifikasikan Tweet Ujaran Kebencian Terhadap Tokoh Publik pada Twitter. Pekan Baru: Universitas Islam Negeri Sultan Syarif Kasim Riau. Diambil dari <http://repository.uinsuska.ac.id/25130>

- [6] Selva.F.(2017). "Penerapan Support Vector Machine (SVM) untuk Pengkategorian Penelitian".Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi). Vol. 1 No. 1 (2017) 19 – 25.
- [7] Indriyono,V dkk.(2015). "Pemanfaatan Algoritma Porter Stemmer Untuk Bahasa Indonesia Dalam Proses Klasifikasi Jenis Buku". Program Pascasarjana Magister Teknik Informatika STMIK AMIKOM Yogyakarta
- [8] Ardhyanto,I dkk. (2017). " Sistem Temu Kembali Informasi : Penerapan Tokenisasi, Stopword Removal, dan Stemming". Diambil dari <https://aprianapanca.wordpress.com/2017/09/22/penerapan-tokenisasi-stopword-removal-dan-stemming/>.
- [9] Yunus,M.(2020)." TF-IDF (Term Frequency-Inverse Document Frequency) : Representasi Vector Data Text".Diambil dari <https://yunusmuhammad007.medium.com/tf-idf-term-frequency-inverse-document-frequency-representasi-vector-data-text-2a4eff56cda>.
- [10] Mulyawan,R.(2020). " Memahami Pengertian Embedding (Penyematan): Manfaat, Cara Melakukan dan Perbedaannya dengan Uploading". Diambil dari <https://rifqimulyawan.com/blog/pengertian-embedding/>.
- [11] Naulak, Chingmuankim (2022). A comparative study of Naive Bayes Classifiers with improved technique on Text Classification. TechRxiv. Preprint. <https://doi.org/10.36227/techrxiv.19918360.v1>
- [12] Utama, Faisal & Warsito, Budi & Sugito, Sugito. (2019). MODEL FEED FORWARD NEURAL NETWORK (FFNN) DENGAN ALGORITMA PARTICLE SWARM SEBAGAI OPTIMASI BOBOT (Studi Kasus : Harga Daging Sapi dari Bank Dunia Periode Januari 2007 – Desember 2018). Jurnal Gaussian. 8. 117-126. 10.14710/j.gauss.v8i1.26626.
- [13] Savelie Cornegruta, Robert Bakewell, Samuel Withey, Giovanni Montana. (2016). Modelling Radiological Language with Bidirectional Long Short-Term Memory Networks. arXiv. <https://doi.org/10.48550/arXiv.1609.08409>