

# Pengaruh Seleksi Fitur *Information Gain* pada Klasifikasi Berita *Hoax* di Twitter dengan Menggunakan Metode *Naive Bayes Multinomial*

1<sup>st</sup> Annisa Dwi Andiani  
Fakultas Informatika  
Universitas Telkom  
Bandung, Indonesia

[annisada@students.telkomuniversity.ac.id](mailto:annisada@students.telkomuniversity.ac.id)

2<sup>nd</sup> Kemas Muslim L  
Fakultas Informatika  
Universitas Telkom  
Bandung, Indonesia

[kemasmuslim@telkomuniversity.ac.id](mailto:kemasmuslim@telkomuniversity.ac.id)

**Abstrak** - Indonesia merupakan salah satu negara yang memiliki banyak pengguna media sosial, konsumsi media sosial yang tinggi tanpa dibarengi dengan sikap kritis dalam melakukan filter informasi yang didapat membuat berita *hoax* menjadi semakin mudah tersebarluaskan. *Hoax* merupakan berita yang disebarluaskan dengan tujuan agar publik mempercayai hal yang tidak diketahui kebenarannya. *Hoax* dapat menimbulkan adanya kecemasan dan permusuhan bagi pihak yang terpapar. Pada penelitian tugas akhir ini, dibangun sistem klasifikasi berita *hoax* di twitter dengan menggunakan metode *naive bayes multinomial* yang dikombinasikan menggunakan pembobotan TF-IDF serta penggunaan seleksi fitur *information gain*. Hasil akhir pengujian menunjukkan bahwa penggunaan *information gain* pada klasifikasi *hoax* ini dapat mengurangi nilai *overfitting* dari akurasi. Hasil akurasi terbaik yang didapat dari penelitian ini adalah sebesar 79,87% dengan menggunakan klasifikasi *Naive Bayes Multinomial*, pembobotan TD-IDF, dan tanpa penggunaan seleksi fitur *Information Gain*.

**Kata kunci** : *hoax*, twitter, TF-IDF, *information gain*, *naive bayes multinomial*

## I. PENDAHULUAN

### A. Latar Belakang

Ditengah perkembangan era teknologi digital, media sosial menjadi sarana yang paling banyak digunakan untuk berbagi dan bertukar informasi. Berdasarkan survey yang dilakukan oleh DataIndonesia [1], pada tahun 2023 indonesia menduduki peringkat kelima sebagai negara dengan jumlah pengguna media sosial terbesar di dunia, dengan jumlah pengguna sebanyak 167 juta setara dengan 60.4% jumlah penduduk di Indonesia. Konsumsi media sosial yang tinggi tersebut dapat menyebabkan informasi menjadi semakin mudah tersebarluaskan, namun minimnya sikap kritis dalam melakukan filter informasi yang didapat bisa membuat berita *hoax* menjadi tersebar dengan mudah [2]. Mastel.id [3] telah melakukan survey mengenai penyebaran berita *hoax* di Indonesia dan ditemukan

bahwa sosial media menjadi saluran penyebaran berita *hoax* tertinggi dengan persentase 80,5%.

*Hoax* merupakan berita yang sengaja dipalsukan lalu disebarluaskan tanpa dasar kebenaran, *hoax* digunakan untuk menipu publik agar mempercayai sesuatu yang tidak terjadi [4]. *Hoax* dapat menimbulkan adanya bias informasi di masyarakat, selain itu juga dapat memunculkan adanya kebencian, penggiringan opini dan permusuhan [5]. Sehingga diperlukan adanya upaya untuk mengurangi penyebaran *hoax*, salah satunya dengan membangun sistem yang dapat mendeteksi *hoax*.

Penelitian mengenai deteksi *hoax* sudah dilakukan dengan menggunakan berbagai metode. Pada penelitian ini akan dibangun sistem klasifikasi *hoax* pada twitter yang mengimplementasikan seleksi fitur *Information Gain* serta pembobotan TF-IDF pada metode klasifikasi *Naive Bayes Multinomial*. Tujuan dari penelitian ini adalah untuk mengetahui pengaruh penggunaan *Information Gain* terhadap performansi dari sistem yang dibangun. *Naive Bayes Multinomial* dipilih sebagai metode pada penelitian ini karena metode ini dapat mengklasifikasikan teks dengan baik [6], serta penggunaan pembobotan TF-IDF dalam klasifikasi dapat meningkatkan akurasi performansi menjadi lebih optimal [7]. Penggunaan fitur seleksi dapat meningkatkan nilai performansi dari sistem yang dibangun, *Information Gain* merupakan metode yang efisien digunakan untuk seleksi fitur karena mampu menentukan fitur yang paling merepresentasikan suatu dokumen dan juga dapat meningkatkan performa klasifikasi [8].

### B. Topik dan Batasannya

Berdasarkan latar belakang diatas, maka topik yang dibahas dalam tugas akhir ini yaitu bagaimana menerapkan seleksi fitur *Information Gain* dengan model klasifikasi *Naive Bayes Multinomial* dan pembobotan TF-IDF pada identifikasi berita *hoax*. Adapun Batasan masalah pada tugas akhir ini adalah sebagai berikut:

1. Data yang digunakan merupakan hasil *crawling* dari Twitter.
2. Data yang digunakan merupakan kategori sosial politik di Indonesia.
3. Data yang digunakan berjumlah 5047 tweet.
4. Pemberian label pada data dilakukan secara manual dengan dua kategori : *hoax* dan *nonhoax*.

### C. Tujuan

Penelitian ini bertujuan untuk mengevaluasi pengaruh penggunaan seleksi fitur *Information Gain* pada klasifikasi berita *hoax* di twitter dengan menggunakan metode klasifikasi *Naive Bayes Multinomial* dan pembobotan TF-IDF.

### D. Organisasi Tulisan

Urutan penulisan dalam penelitian ini adalah sebagai berikut: bagian satu berisi latar belakang penelitian, bagian dua menunjukkan studi literatur mengenai teori yang digunakan, bagian tiga berisi alur sistem yang dibangun, bagian empat menjelaskan mengenai hasil pengujian, dan bagian lima berisi kesimpulan dan saran untuk penelitian selanjutnya.

## II. STUDI TERKAIT

### A. Penelitian Terkait

Berdasarkan hasil studi literatur, penelitian mengenai klasifikasi *hoax* sudah pernah dilakukan sebelumnya dengan menggunakan berbagai macam metode yang berbeda. Penelitian pertama dilakukan oleh Sandifer pada tahun 2018, penelitian ini dilakukan klasifikasi dengan membandingkan tiga metode yaitu *Naive Bayes Multinomial*, *Bernouli Naive Bayes*, dan *Logistic Regression Model*. Dari penelitian ini *Naive Bayes Multinomial* mendapat hasil akurasi paling tinggi untuk klasifikasi dokumen yaitu sebesar 85,9% [6].

Kemudian penelitian kedua dilakukan pada tahun 2021 dengan menggunakan metode *Naive Bayes Multinomial* dilakukan oleh Candra Surya, pada penelitian ini bertujuan untuk mengetahui pengaruh penggunaan pembobotan TF-IDF pada klasifikasi berita *hoax*. Hasil dari penelitian ini diketahui bahwa penggunaan TF-IDF meningkatkan nilai akurasi menjadi lebih tinggi yaitu diperoleh nilai akurasi sebesar 72,06% jika dibandingkan dengan hasil pengujian tanpa menggunakan pembobotan TF-IDF hasil akurasinya sebesar 71,65% [9].

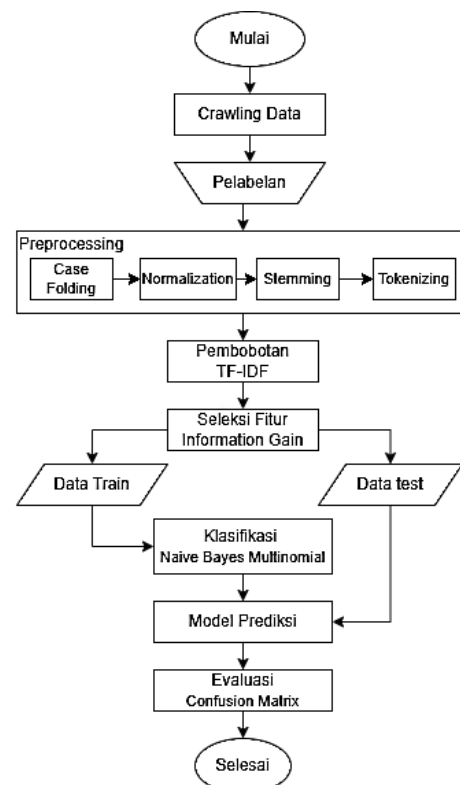
Penelitian selanjutnya dilakukan oleh Husnul Khatimah, penelitian ini dilakukan dengan menggunakan metode *Convolutional Neural Network* (CNN). Penelitian ini membandingkan pengaruh seleksi fitur *Information Gain* pada identifikasi berita *hoax*. Hasil yang didapat menunjukkan bahwa tanpa penggunaan seleksi fitur *Information Gain* nilai akurasi dari model yang dibangun adalah 68,96% sedangkan dengan menggunakan *Information Gain*

nilai dihasilkan nilai akurasi yang lebih optimal yaitu 95,56% [7].

### B. Hoax

*Hoax* bisa diartikan sebagai berita bohong yang dalam penyebarannya menggunakan informasi meyakinkan tetapi tidak dapat diverifikasi kebenarannya [10]. *Hoax* juga dapat diartikan sebagai informasi yang di sebar dan isinya sudah dimanipulasi untuk menutupi suatu fakta tertentu [11]. *Hoax* digunakan untuk tujuan menipu pembaca dan membuat opini publik [12]. Penyebaran *hoax* dapat dipicu oleh dua motif yakni motif politik dan ekonomi, ada *hoax* yang dibuat dengan tujuan untuk mendapat sensasi namun ada pula yang memang dibuat dengan tujuan untuk menyalurkan aspirasi politik [13].

## III. SISTEM YANG DIBANGUN



Gambar 1.  
Perancangan Sistem

Gambar 1 menunjukkan tahapan yang dilakukan dalam membangun sistem, proses ini dimulai dengan melakukan *crawling* data, kemudian pelabelan, *preprocessing*, pembobotan, seleksi fitur, lalu dilakukan split data dan proses klasifikasi yang menghasilkan model prediksi, lalu dilakukan evaluasi untuk mengukur performansi dari sistem yang dibangun.

### A. Crawling Data

*Crawling Data* adalah proses pengumpulan data yang akan digunakan sebagai referensi oleh sistem, data yang dikumpulkan berasal dari twitter yang didapat menggunakan API yang telah disediakan oleh *twitter developer*. Setiap melakukan satu kali *crawling*, data yang didapat berjumlah 100 tweet terbaru yang dapat dicari dengan menggunakan kata kunci yang diinginkan. Hasil *crawling* data dapat dilihat pada tabel.1 sebagai berikut.

Tabel 1.  
Hasil Crawling Data

User name	Tweet
<b>Fattasyah</b>	RT @Hilmi28: Status sy bbrpa hari yg lalu terbukti kan, walaupun Cuma Analisa Warkop fÆ, fÆ, fÆ... fÆ fÆ, fÆ. Ok deh, Pak Anies, Pak Prabowo sdh hampir pasti Nya jadi fÆ

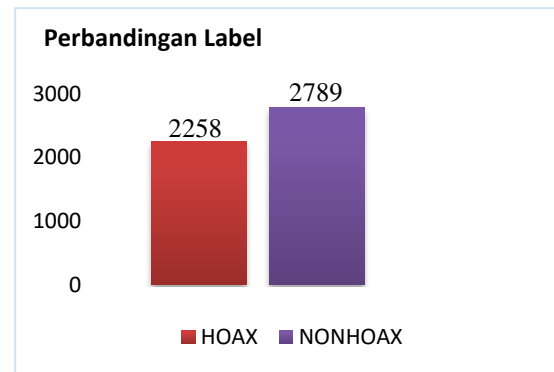
Tabel 1 menunjukkan hasil crawling data, data yang diambil adalah username pengguna dan isi tweet. Data yang didapatkan dari hasil *crawling* berjumlah 5047 tweet dengan kata kunci yang digunakan adalah isu seputar sosial politik di Indonesia.

**B. Pelabelan**

Pelabelan adalah proses penentuan kelas dari tweet dengan cara memberi label *hoax* atau *nonhoax*. Pelabelan dilakukan secara manual oleh tiga orang. Menurut Kominfo dan Dewan pers, berikut merupakan acuan suatu tweet dikategorikan *hoax* [14] [15]:

1. Konten parodi, memuat sindiran kepada pihak tertentu.
2. Konten menyesatkan, memuat informasi yang tidak sesuai dengan data dan fakta.
3. Ketidakjelasan sumber berita, memuat informasi yang kebenarannya tidak dapat dibuktikan.
4. Pemberitaan tidak berimbang yang cenderung menyudutkan pihak tertentu.
5. Bermuatan fanatisme yang mengagungkan pihak tertentu.
6. Judul dan kalimatnya provokatif, memuat informasi yang berisi penghakiman pada pihak tertentu.
7. Konten yang muatannya dapat menyebabkan kebencian, kecemasan, dan permusuhan bagi masyarakat yang terpapar informasi, muatan seperti ini dapat memunculkan adanya perdebatan sehingga menciptakan permusuhan.

Setelah dilakukan pelabelan dengan menggunakan acuan poin diatas, dihasilkan perbandingan data set yang dapat dilihat pada gambar 2 berikut



Gambar 2.  
Perbandingan Label

Gambar 2 menunjukkan hasil perbandingan data setelah diberi label, dihasilkan data berupa 44,74% tweet berlabel *hoax* dan 55,27% tweet berlabel *nonhoax*.

**C. Preprocessing**

*Preprocessing* adalah proses pengolahan data dengan cara mengubah bentuk teks yang tidak terstruktur menjadi bentuk yang mudah diproses oleh sistem. Contoh tahap *Preprocessing* dapat dilihat pada tabel 2 sebagai berikut.

Tabel 2.  
Hasil Preprocessing

<b>Input</b>	RT @Hilmi28: Status sy bbrpa hari yg lalu terbukti kan, walaupun cuma analisa Warkop! fÆ... fÆ, fÆ. Ok deh, Pak Anies, Pak Prabowo sdh hampir pasti Nya jadi fÆ
<b>Case Folding</b>	status sy bbrpa hari yg lalu terbukti kan walaupun cuma analisa warkop ok deh pak anies pak prabowo sdh hampir pasti nya jadi
<b>Normalization</b>	status saya beberapa hari yang lalu terbukti kan walaupun cuma analisa warkop ok deh pak anies pak prabowo sudah hampir pasti nya jadi
<b>Stemming</b>	status saya beberapa hari yang lalu bukti kan walaupun cuma analisa warkop ok deh pak anies pak prabowo sudah hampir pasti nya jadi
<b>Tokenizing</b>	['status', 'saya', 'beberapa', 'hari', 'yang', 'lalu', 'bukti', 'kan', 'walaupun', 'cuma', 'analisa', 'warkop', 'ok', 'deh', 'pak', 'anies', 'pak', 'prabowo', 'sudah', 'hampir', 'pasti', 'nya', 'jadi']

Tabel 2 menunjukkan tahap yang dilakukan dalam preprocessing, proses *Preprocessing* yang dilakukan adalah *case folding* yang bertujuan untuk

menghilangkan karakter selain huruf a-z, *normalization* untuk mengubah kata menjadi kata baku sesuai kamus, *stemming* untuk mengubah kata menjadi kata dasar dan *tokenizing* yang bertujuan untuk memecah kalimat menjadi kata.

#### D. Pembobotan TF-IDF

Setelah melewati tahap preprocessing, kemudian dilakukan proses pembobotan nilai pada setiap kata dengan menggunakan TF-IDF. Dalam proses pembobotan ini diperlukan adanya *Term Frequency* (TF) yaitu menghitung jumlah kata dalam suatu dokumen, dan diperlukan *Inverse Document Frequency* (IDF) yaitu menghitung frekuensi kemunculan kata pada seluruh dokumen. Jika frekuensi suatu kata muncul lebih sering, maka nilai bobot kata tersebut menjadi semakin besar. Pembobotan TF-IDF memiliki persamaan berikut [16].

$$W_{dt} = tf_{dt} \times idf_t \quad (1)$$

Dimana  $W_{dt}$  merupakan bobot kata  $t$  terhadap dokumen  $d$ ,  $tf_{dt}$  merupakan jumlah kemunculan kata  $t$  dalam dokumen  $d$ , dan  $idf$  merupakan nilai *Inverse Document Frequenty*. Nilai  $idf$  didapat dari persamaan berikut.

$$idf = \log\left(\frac{D}{df}\right) \quad (2)$$

Dimana  $D$  merupakan jumlah dokumen keseluruhan dan  $df$  merupakan jumlah dokumen yang mengandung kata  $t$ . Contoh hasil pembobotan TF-IDF dapat dilihat pada tabel 3 sebagai berikut.

Tabel 3.  
Hasil Pembobotan

Fitur	Skor TFIDF
ganjar	117.6493
prabowo	94.9977
korupsi	83.9907
pilpres	78.7585
indonesia	77.9683

Tabel 3 menunjukkan nilai hasil pembobotan TFIDF, pada tahap pembobotan ini nilai skor didapat dari hasil perhitungan dengan menggunakan persamaan 1. Fitur yang telah diberi bobot kemudian diurutkan berdasarkan skor *ranking* nilai tertinggi.

#### E. Seleksi Fitur *Information Gain*

Data yang telah memiliki bobot kemudian di seleksi dengan menggunakan seleksi fitur *information gain* agar mendapat peringkat fitur yang paling berpengaruh dan relevan terhadap dokumen, semakin besar nilai *information gain* maka semakin besar pula pengaruh suatu atribut terhadap pengklasifikasian data. Nilai *Information Gain* didapat dari hasil perhitungan nilai entropy [16].

$$Gain(S, A) = Entropy(S) - Entropy(S, A) \quad (3)$$

Dimana  $Gain(S, A)$  merupakan nilai *information gain*.  $Entropy(S)$  merupakan nilai dari *entropy* sebelum pemisahan.  $Entropy(S, A)$  merupakan nilai *entropy* setelah pemisahan.

$$Entropy(S) = \sum_{i=1}^n - p_i \log_2 p_i \quad (4)$$

Dimana nilai  $p_i$  merupakan peluang data  $S$  didalam kelas  $i$ .  $K$  adalah jumlah untuk kelas dari variable  $S$ .

$$Entropy(S, A) = \sum_{i=1}^n - \frac{S_i}{S} \times Entropy(S_i) \quad (5)$$

Dimana nilai  $i$  merupakan semua nilai yang mungkin dari atribut  $A$ .  $S_i$  merupakan subset dari  $S$  dimana atribut  $A$  bernilai  $i$ . Contoh data setelah dilakukan seleksi fitur *Information Gain* dapat dilihat pada tabel 4

Tabel 4.  
Hasil Seleksi Fitur

Fitur	Skor TFIDF	Nilai Information Gain
ganjar	117.6493	0.3194
prabowo	94.9977	0.1638
korupsi	83.9907	0.7390
pilpres	78.7585	0.2913
indonesia	77.9683	0.6022

#### F. Metode Klasifikasi *Naive Bayes Multinomial*

Tahap ini merupakan proses klasifikasi, dilakukan pembagian data *set* menjadi data *train* dan data *test*. Kemudian data *train* yang memiliki bobot angka akan dijadikan sebagai input kedalam fungsi klasifikasi menggunakan algoritma *Naive Bayes Multinomial*.

*Naive Bayes Multinomial* merupakan model pengembangan dari algoritma *bayes* yang cocok digunakan dalam pengklasifikasian teks atau dokumen, pada klasifikasi *Naive Bayes Multinomial* kelas dokumen tidak hanya ditentukan oleh kata yang muncul namun juga oleh jumlah kemunculannya [17]. Pada *Naive Bayes Multinomial* proses klasifikasi dilakukan dengan tiga tahap, tahap pertama dilakukan pencarian nilai peluang prior, tahap kedua dilakukan perhitungan peluang *conditional*, kemudian dilakukan pemilihan kategori [18].

*Naive bayes Multinomial* melakukan klasifikasi dengan menggunakan nilai probabilitas suatu dokumen  $d$  berada di kelas  $c$ , dapat dihitung menggunakan persamaan [19].

$$P(c|d) = P(c) \times P(t1|c) \times P(t2|c) \times \dots \times P(tk|c) \quad (6)$$



menggunakan pembobotan TF-IDF. Kemudian, pada skenario keempat dilakukan pengujian terhadap model yang dibangun dengan menggunakan data baru atau data *real*.

A. Hasil Pengujian

1. Hasil Pengujian Klasifikasi

Pada skenario pertama ini, pengujian dilakukan sebanyak lima kali dengan menggunakan banyak data uji yang berbeda yaitu 10%, 20%, 30%, 40%, dan 50% data uji. Hasil pengujian klasifikasi dapat dilihat pada tabel 7 berikut.

TABEL 7.  
Pengujian Klasifikasi

Data Uji	Akurasi Train	Akurasi Tes	Precision	Recall	F1-Score
10%	86,36%	74,46%	75,56%	74,46%	73,85%
20%	86,93%	75,15%	76,11%	75,15%	74,46%
30%	86,73%	74,79%	76,07%	74,79%	74,01%
<b>40%</b>	<b>87,62%</b>	<b>75,79%</b>	<b>76,85%</b>	<b>75,79%</b>	<b>75,04%</b>
50%	89,10%	74,06%	74,77%	74,06%	73,24%
<b>Rata-rata</b>	<b>87,35%</b>	<b>74,85%</b>	<b>75,87%</b>	<b>74,85%</b>	<b>74,12%</b>

Tabel 7 menunjukkan hasil pengujian menggunakan metode klasifikasi *Naive Bayes Multinomial*, hasil akurasi tertinggi ditunjukkan oleh pengujian dengan menggunakan data uji sebanyak 40% dengan nilai akurasi train 87,62% dan akurasi test 75,79%.

2. Hasil Pengujian Klasifikasi dan Pembobotan

Pada skenario kedua ini dilakukan pengujian terhadap metode klasifikasi *Naive Bayes Multinomial* yang dikombinasikan dengan pembobotan TF-IDF, pengujian dilakukan sebanyak lima kali dengan menggunakan jumlah data uji yang berbeda yaitu 10%, 20%, 30%, 40%, dan 50% data uji. Hasil pengujian untuk skenario kedua ini dapat dilihat pada tabel 8 berikut.

TABEL 8.  
Pengujian Klasifikasi + Pembobotan

Data uji	Akurasi Train	Akurasi Tes	Precision	Recall	F1-Score
10%			77,25%	77,23%	77,90%
	86,97%	77,23%			
20%			78,89%	78,91%	79,85%
	87,10%	78,91%			
<b>30%</b>	<b>87,44%</b>	<b>79,87%</b>	<b>79,84%</b>	<b>79,87%</b>	<b>79,85%</b>
40%			79,77%	79,80%	79,78%
	87,92%	79,80%			
50%			78,01%	78,02%	78,01%
	88,87%	78,02%			
<b>Rata-rata</b>	<b>87,66%</b>	<b>78,77%</b>	<b>78,75%</b>	<b>78,77%</b>	<b>78,76%</b>

Tabel 8 menunjukkan hasil pengujian menggunakan metode klasifikasi *Naive Bayes Multinomial* yang di kombinasi dengan pembobotan TF-IDF, hasil akurasi tertinggi ditunjukkan oleh

pengujian dengan menggunakan data uji sebanyak 30% dengan nilai akurasi train sebesar 87,44% dan akurasi test sebesar 79,87%.

3. Hasil Pengujian Klasifikasi, Pembobotan, dan Seleksi Fitur

Pada skenario ketiga ini dilakukan pengujian terhadap metode klasifikasi *Naive Bayes Multinomial* yang dikombinasikan dengan pembobotan TF-IDF dan juga menggunakan seleksi fitur *Information Gain*, pengujian dilakukan menggunakan jumlah data uji dan nilai *threshold* yang berbeda. Data uji yang digunakan dalam skenario ini yaitu 10%, 20%, 30%, 40%, dan 50% data uji, kemudian untuk nilai *threshold* yang diuji yaitu 0.01, 0.02, 0.03, 0.04, 0.05, 0.06, 0.07, 0.08, dan 0.09. Hasil pengujian untuk skenario ketiga ini dapat dilihat pada tabel 9 berikut.

TABEL 9.  
Pengujian Klasifikasi + Pembobotan + Seleksi Fitur

Tresh old	Data Uji	Akurasi Train	Akurasi Tes	Precision	Recall	F1 Score
0,01	10	80,28%	73,86%	74,48%	73,86%	73,41%
	20	80,39%	74,75%	74,98%	74,75%	74,39%
	30	80,36%	76,50%	76,87%	76,50%	76,17%
	40	81,25%	76,68%	76,87%	76,68%	76,37%
	50	81,97%	74,89%	74,88%	74,89%	74,59%
0,02	10	80,22%	73,27%	74,03%	73,27%	72,73%
	20	80,47%	74,55%	74,85%	74,55%	74,15%
	30	80,14%	76,63%	77,09%	76,63%	76,27%
	40	81,18%	76,88%	77,12%	76,88%	76,54%
	50	81,66%	75,01%	75,01%	75,01%	74,70%
0,03	10	79,93%	73,27%	74,11%	73,27%	72,70%
	20	80,24%	74,55%	74,87%	74,55%	74,13%
	30	79,82%	76,50%	76,97%	76,50%	76,13%
	<b>40</b>	<b>80,79%</b>	<b>76,93%</b>	<b>77,21%</b>	<b>76,93%</b>	<b>76,57%</b>
	50	81,42%	75,13%	75,16%	75,13%	74,80%
0,04	10	79,78%	73,07%	73,86%	73,07%	72,51%
	20	80,24%	74,16%	74,46%	74,16%	73,73%
	30	79,74%	76,37%	76,83%	76,37%	75,99%
	40	80,59%	76,63%	76,87%	76,63%	76,29%
	50	81,42%	74,89%	74,91%	74,89%	74,56%
0,05	10	79,80%	73,47%	74,20%	73,47%	72,95%
	20	80,24%	74,46%	74,87%	74,46%	73,98%
	30	79,88%	76,70%	77,19%	76,70%	76,32%
	40	80,55%	76,73%	77,01%	76,73%	76,37%

0,06	50	81,26	74,81	74,83	74,81	74,48
	%	%	%	%	%	%
	10	79,71	73,07	73,94	73,07	72,48
	%	%	%	%	%	%
	20	79,92	74,46	74,90	74,46	73,97
%	%	%	%	%	%	
0,07	30	<b>79,54</b>	<b>76,63</b>	77,20	76,63	76,23
	%	%	%	%	%	%
	40	80,29	76,44	76,73	76,44	76,05
	%	%	%	%	%	%
	50	80,94	74,65	74,70	74,65	74,29
%	%	%	%	%	%	
0,08	10	79,34	72,87	73,93	72,87	72,19
	%	%	%	%	%	%
	20	79,65	74,65	75,20	74,65	74,12
	%	%	%	%	%	%
	30	79,17	76,37	76,96	76,37	75,94
%	%	%	%	%	%	
0,09	40	79,70	76,29	76,60	76,29	75,88
	%	%	%	%	%	%
	50	80,55	74,65	74,70	74,65	74,29
	%	%	%	%	%	%
	10	79,03	73,47	74,45	73,47	72,85
%	%	%	%	%	%	
0,08	20	79,43	74,55	75,08	74,55	74,03
	%	%	%	%	%	%
	30	78,89	75,91	76,49	75,91	75,46
	%	%	%	%	%	%
	40	79,53	75,84	76,13	75,84	75,43
%	%	%	%	%	%	
0,09	50	80,35	74,46	74,49	74,46	74,09
	%	%	%	%	%	%
	10	78,70	73,66	74,80	73,66	73,00
	%	%	%	%	%	%
	20	79,08	73,96	74,55	73,96	73,37
%	%	%	%	%	%	
0,09	30	78,69	75,12	75,76	75,12	74,61
	%	%	%	%	%	%
	40	79,20	75,45	75,75	75,45	75,01
	%	%	%	%	%	%
	50	80,27	73,90	73,94	73,90	73,51
%	%	%	%	%	%	

Tabel 9 menunjukkan hasil pengujian menggunakan metode klasifikasi *Naive Bayes Multinomial* yang di kombinasi dengan pembobotan TF-IDF dan penggunaan seleksi fitur *Information Gain*, hasil akurasi tertinggi ditunjukkan oleh pengujian menggunakan nilai *threshold* 0,03 dan data uji sebanyak 40% menghasilkan nilai akurasi train sebesar 80,79% dan akurasi test sebesar 76,93%.

Kemudian untuk mencari nilai rata rata akurasi terbaik dari pengujian klasifikasi dengan menggunakan *Information Gain* ini, dilakukan pengujian kembali sebanyak lima kali dengan menggunakan data uji yang memiliki nilai akurasi terbesar yaitu 40% dengan nilai *threshold* 0,03. Hasil pengujian ini dapat dilihat pada tabel 10 berikut.

TABEL 10.  
Pengujian Nilai Rata-rata dari Threshold dan Data Uji Terbaik

Thres	Data	Akur	Akur	Presic	Reca	FI-
hold	Uji	asi	asi	ion	Il	Scor
		Trai	Tes			e
		n				
0,03	40%	80,08	76,88	77,12	76,8	76,5
		%	%	%	8%	4%
		<b>80,79</b>	<b>76,93</b>	<b>76,21</b>	<b>76,9</b>	<b>76,5</b>
		%	%	%	3%	7%
		80,58	76,74	76,87	76,6	76,2
		%	%	%	3%	9

	80,35	76,83	77,01	76,7	76,3
	%	%	%	3%	7%
	79,54	76,52	77,20	76,6	76,2
	%	%	%	3%	3%
<b>Rata-rata</b>	80,2	76,78	77,08	76,76	76,4
	7%	%	%	%	0%

Tabel 10 menunjukkan hasil pengujian menggunakan metode klasifikasi *Naive Bayes Multinomial* yang di kombinasi dengan pembobotan TF-IDF dan penggunaan seleksi fitur *Information Gain* menggunakan nilai *threshold* 0,03 dan data uji sebanyak 40% menghasilkan nilai rata-rata akurasi train sebesar 80,27% dan rata-rata akurasi test sebesar 76,78%.

4. Hasil Pengujian Model Menggunakan Data Baru  
 Pada skenario keempat ini, dilakukan pengujian terhadap kemampuan model yang dibangun dalam mengklasifikasikan data baru atau data *real*. Hasil dari klasifikasi menggunakan data baru pada model yang dibangun dapat dilihat pada tabel 11 berikut.

TABEL 11.  
Pengujian Model Menggunakan Data Baru

Tweet	Label Aktual	Label Prediksi
Hehehe Benny,, blm kenal ya sm Anies.. apa tdk melihat sejarah di Gub DKI.. siapa teman siapa pendukung.. ujung nya hanya menjadi hiasan..Perubahan.. hanya sebuah Visi.. lihat klu jd president thn 2 dst. Semua akan berubah.. hanya keinginan dan alam pikirannya yg dia jalankan.	Hoax	Hoax
Bukannya merek "NGIBUL" itu anies penciptanya Pantass pendukungnya pada Bodoh orang didukugnya sja tukang NGIBULL atau pandai menata kata	Hoax	Hoax
Salah Bang Sat, Prabowo adalah Orde Baru. Anies juga bagian dan dibesarkan oleh Orde Baru. Ganjar adalah Orde Reformasi. Ganjar adalah harapan.	Hoax	Nonhoax
Ketua Umum DPP Partai Amanat Nasional (PAN) Zulkifli Hasan memberi tanda akan mendukung pencalonan Ganjar Pranowo dan Erick Thohir sebagai Calon Presiden (Capres) dan Calon Wakil	Nonhoax	Nonhoax


Presiden (Cawapres) dalam Pemilihan Presiden (Pilpres) 2024.

Anies diajak naik mobil Nonhoax Nonhoax Jip saat apel siaga 2023 yang digelar PKS di Stadion Madya GBK. Dari atas Jip, Anies lambaikan tangan ke ribuan kader PKS

Tabel 11 menunjukkan hasil klasifikasi prediksi *hoax* yang dilakukan model dari pengujian dengan menggunakan data baru, pada pengujian ini digunakan lima data berupa *tweet* baru yang sudah diberi label. Hasil menunjukkan bahwa model dapat melakukan prediksi terhadap data baru ini, dari lima data *tweet* yang diujikan model berhasil melakukan klasifikasi dan memberikan label prediksi terhadap empat data *tweet* dengan tepat sesuai dengan label aktualnya.

### B. Analisis Hasil Pengujian

Untuk melihat perbandingan rata-rata dari hasil pengujian yang dilakukan masing-masing skenario, data pengujian ditampilkan dalam bentuk gambar. Hasil pengujian dari ketiga skenario dapat dilihat pada gambar 3 berikut.



GAMBAR 3.  
Perbandingan 3 Skenario Pengujian

Gambar 3 menunjukkan bahwa dari pengujian tiga skenario yang dilakukan, skenario pertama memiliki hasil akurasi *test* rata-rata sebesar 74,85% dan akurasi rata-rata *train* 87,35%. Skenario kedua menghasilkan akurasi rata-rata *test* terbaik dibandingkan skenario pengujian yang lain yaitu 78,77%, juga akurasi rata-rata *train* 87,66%. Kemudian, skenario tiga memiliki hasil akurasi *test* rata-rata sebesar 76,87% dengan akurasi rata-rata *train* sebesar 80,27%.

Pada Gambar 3 juga ditunjukkan mengenai selisih nilai dari akurasi *test* dan akurasi *train* dimana skenario pertama memiliki selisih nilai antara *test* dan *train* sebesar 12,5%, kemudian skenario kedua memiliki selisih nilai 8,89% yang berarti pada kedua skenario ini terjadi *overfitting*, dimana *overfitting* ini terjadi ketika sistem yang dibangun tidak dapat mempelajari pola dari data yang telah dianalisis sehingga sistem dapat menghasilkan nilai akurasi

tinggi untuk data *train*, namun memiliki hasil yang jauh lebih rendah pada akurasi data *test* [20], kemudian pada pengujian skenario ketiga memiliki selisih antara *test* dan *train* sebesar 3,49%. Sehingga dapat disimpulkan bahwa penggunaan seleksi fitur *Information Gain* dapat mengurangi nilai *overfitting*, hal ini juga dapat dibuktikan dengan membandingkan hasil selisih akurasi dari setiap rasio yang diujikan menggunakan masing-masing skenario yang menunjukkan hasil bahwa selisih terkecil antara nilai *test* dan *train* dihasilkan pada pengujian dengan menggunakan seleksi fitur *Information Gain* menggunakan nilai *threshold* 0,06 dengan data uji 30% dihasilkan selisih akurasi 2,91%, hal ini menunjukkan bahwa penggunaan seleksi fitur *Information Gain* dapat mengurangi *overfitting* meskipun bukan merupakan nilai akurasi terbaik.

## V. KESIMPULAN

Berdasarkan hasil pengujian dan analisis yang dilakukan, pada penelitian tugas akhir ini dihasilkan kesimpulan bahwa model yang dibangun dapat melakukan klasifikasi untuk prediksi *hoax* dengan baik, hal ini dibuktikan dengan pengujian menggunakan data baru pada skenario empat memiliki hasil klasifikasi yang cukup tepat. Kemudian, pada penelitian tugas akhir ini juga didapat kesimpulan bahwa penggunaan seleksi fitur *Information Gain* untuk klasifikasi *hoax* menggunakan metode *Naive Bayes Multinomial* dan pembobotan TF-IDF dapat mengurangi nilai *overfitting*, meskipun hasil akurasi terbaik yaitu 79,87% dihasilkan dari pengujian menggunakan klasifikasi *Naive Bayes Multinomial* dengan menggunakan pembobotan TF-IDF tanpa penggunaan seleksi fitur *Information Gain*. Kemudian pada penelitian ini juga dihasilkan bahwa nilai *threshold* yang dipilih dapat mempengaruhi hasil kinerja seleksi fitur *Information Gain*, terbukti dengan penggunaan nilai *threshold* yang berbeda dapat menghasilkan nilai akurasi yang berbeda.

Pada penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih banyak dan juga menggunakan data dengan pembagian kelas yang seimbang, kemudian penulis juga menyarankan untuk menggunakan fitur seleksi yang lain guna mencari hasil yang lebih optimal untuk diterapkan dalam klasifikasi *Naive Bayes Multinomial*.

## REFERENSI

- [1] DataIndonesia.id, "Pengguna media sosial di Indonesia," 3 February 2023. [Online]. Available: <https://dataindonesia.id/internet/detail/pengguna-media-sosial-di-indonesia-sebanyak-167-juta-pada-2023>. [Accessed 21 April 2023].



- [2] Annisa, A. Rahmadhany, A. A. Safitri and I. , "Fenomena Penyebaran Hoax dan Hate Speech pada Media Sosial," *Jurnal Teknologi dan Informasi Bisnis*, vol. 3, no. 1, pp. 30-43, 2021.
- [3] MASTEL, "mastel.id," [Online]. Available: <https://mastel.id/hasil-survey-wabah-hoax-nasional-2019/>. [Accessed 24 01 2023].
- [4] D. R. Rahadi, "Perilaku Pengguna dan Informasi Hoax di Media Sosial," *Jurnal Manajemen & Kewirausahaan*, vol. 5, no. 1, pp. 58-70, 2017.
- [5] R. E. Hamzah and C. E. Putri, "Mengenal dan Mengantisipasi Hoax di Media Sosial pada Kalangan Pelajar," *Jurnal Abdi MOESTOPO*, Vols. Vol. 03, No. 01, no. ISSN: 2599-249X, pp. 9-12, 2020.
- [6] A. V. Sandifer, C. Wilson and A. Olmsted, "Detection of Fake Online Hotel Reviews," in *International Conference for Internet Technology and Secured Transactions (ICITST)*, 2017.
- [7] H. K. Farid, E. B. Setiawan and I. Kurniawan, "Implementasi Seleksi Fitur Information Gain pada Pendeteksian Berita Hoax di Twitter dengan Menggunakan Convolutional Neural Network (CNN)," *Indo-JC Indonesia Journal on Computing*, vol. 5, no. 3, 2020.
- [8] A. E. Irsad, Y. A. Sari and M. A. Fauzi, "Seleksi Fitur Information Gain untuk Klasifikasi Informasi Tempat Tinggal di Kota Malang Berdasarkan Tweet Menggunakan Metode Naïve Bayes dan Pembobotan TF-IDF-CF," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vols. Vol. 3, No. 5, no. e-ISSN: 2548-964X, pp. 4907-4913, 2019.
- [9] C. S. Sriyano and E. B. Setiawan, "Pendeteksian Berita Hoax Menggunakan Naive Bayes Multinomial Pada Twitter dengan Fitur Pembobotan TF-IDF," *e-Proceeding of Engineering*, Vols. Vol.8, No.2, no. ISSN : 2355-9365, p. 3396, Vol.8, No.2 April 2021.
- [10] KOMINFO, "kominfo.go.id," Melawan "hoax" ] - Kementerian Komunikasi dan Informatika, [Online]. Available: [https://www.kominfo.go.id/content/detail/8790/melawan-hoax/0/sorotan\\_media](https://www.kominfo.go.id/content/detail/8790/melawan-hoax/0/sorotan_media). [Accessed 24 01 2023].
- [11] C. Kamilah and N. Atnan, "Analisis ] Kemampuan Mahasiswa Bandung Raya dalam Mengidentifikasi Hoax," *Jurnal Ilmu Komunikasi*, vol. 10, no. 1, 2021.
- [12] C. Juditha, "Interaksi Komunikasi Hoax di ] Media Sosial serta Antisipasinya," *Jurnal Pekommas*, Vols. 3, No 1, 2018.
- [13] H. Chumairoh, "Ancaman Berita Bohong di ] Tengah Pandemi Covid-19," *VOX POPULI*, vol. Vol.3, no. ISSN (Print): 2087-3360 (Online): 2714-7657, pp. 22-30, 2020.
- [14] KOMINFO, "Ciri Ciri dan akibat hoaks," 13 ] March 2019. [Online]. Available: <https://aptika.kominfo.go.id/2019/03/ciri-ciri-akibat-dan-kenapa-kita-mudah-percaya-hoaks/>. [Accessed 22 April 2023].
- [15] T. H. Lubis and I. Koto, "Diskursus Kebenaran ] Berita Berdasarkan Undang-Undang Nomor 40 Tahun 1999 Tentang Pers Dan Kode Etik Jurnalistik," *DELEGALATA (Jurnal Ilmu Hukum)*, vol. 5, no. 2, 2020.
- [16] B. Irena and E. B. Setiawan, "Identifikasi Berita ] Palsu (Hoax) Pada Media Sosial Twitter dengan Metode Decision Tree C4.5," *Resti (Rekayasa Sistem dan Teknologi Informasi)*, Vols. vol.9,, no. ISSN: 2355-9365, p. 1853, 2020.
- [17] D. H. Kalokasari, I. M. Shofi and A. H. ] Setyaningrum, "Implementasi Algoritma Multinomial Naive Bayes Classifier Pada Sistem Klasifikasi Surat Keluar (Studi Kasus : DISKOMINFO Kabupaten Tangerang)," *JURNAL TEKNIK INFORMATIKA*, Vols. VOL.10 NO.2,, p. 109, 2017.
- [18] F. Handayani and F. S. Pribadi, "Implementasi ] Algoritma Naive Bayes Classifier dalam Pengklasifikasian Teks Otomatis Pengaduan dan Pelaporan Masyarakat melalui Layanan Call Center 110," *Jurnal Teknik Elektro*, Vols. 7, No.1, 2015.
- [19] A. Sabrani, I. G. P. W. Wedashwara W and F. ] Bimantoro, "Metode Multinomial Naive Bayes Untuk Klasifikasi Artikel Online Tentang Gempa di Indonesia," *JTIKA*, Vols. Vol. 2, No. 1., no. ISSN:2657-0327, 2020.
- [20] W. A. Firmansyach, "Analisa Terjadinya ] Overfitting dan Underfitting pada Algoritma Naive Bayes dan Decision Tree dengan Teknik Cross Validation," *JATI (Jurnal Mahasiswa Teknik Informatika)*, Vols. 7, No 1, 2023.